



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO  
POSGRADO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN  
COMPUTO CIENTÍFICO

# EL APRENDIZAJE POR REFUERZO COMO MODELO DE ACTIVIDAD CEREBRAL

T E S I S

QUE PARA OPTAR POR EL GRADO DE :

MAESTRA EN CIENCIAS DE LA COMPUTACIÓN

P R E S E N T A :

KARLA KARINA SÁNCHEZ TORRES

T U T O R :

DRA. SUEMI RODRÍGUEZ ROMO  
FACULTAD DE ESTUDIOS SUPERIORES CUAUTITLÁN, UNAM

CIUDAD UNIVERSITARIA, CDMX, AGOSTO, 2020



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



*Dedicado a mis padres, hermanas y amigos  
por todo su apoyo y palabras de aliento,  
que a pesar de la distancia siempre estuvieron conmigo,  
a mis profesores por su apoyo incondicional.*



# Reconocimientos

---

Quiero agradecer primeramente a Dios por haberme permitido llegar a este momento tan especial y por haberme dado salud para lograr mis objetivos y alcanzar una meta más en mi vida.

A la Universidad Nacional Autónoma de México, la cual me brindó la oportunidad de desarrollarme tanto académicamente como profesional y personal dentro de sus aulas al realizar mis estudios de posgrado.

Al posgrado en Ciencia e Ingeniería de la Computación y al personal administrativo, por todas las facilidades que me brindaron durante la realización de este trabajo.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT - México), por haberme apoyado con una beca durante mis estudios de Maestría.

Al Programa de Apoyo a Proyectos de Investigación e Innovación Tecnológica (PAPIIT) de la UNAM IT102920.

A mi directora de tesis la Dra. Suemi Rodríguez Romo, por permitirme trabajar a su lado, por compartir su tiempo, conocimientos, paciencia, apoyo y enseñanzas. Por haberme guiado durante este proceso con tanta dedicación y compromiso. Por enseñarme que no hay secretos para el éxito, que éste se alcanza preparándose, organizándose, trabajando arduamente y aprendiendo de los errores.

Al Centro de Investigaciones Teóricas en la FES-Cuautitlán, mi segunda casa, porque en él encontré personas que me hicieron sentir de su propia familia, que me acogieron y me brindaron todo el apoyo siempre que lo necesite sin esperar nada a cambio, solo verme triunfar en cada uno de mis propósitos. En especial a mis maestros, el Mtro. Felipe Vargas Torres y el Dr. Óscar Ibáñez, quienes nunca desistieron al enseñarme, a ellos que continuaron depositando su esperanza en mí, por brindarme todo su apoyo y solidaridad. Al Mtro. Rene Perez Moroyoqui y Mtro. Fernando Patlán Cardoso, quienes me brindaron de su valioso tiempo y conocimientos para ser de fundamental apoyo durante la realización de esta tesis.

A los miembros del jurado de corrección de tesis y examen de grado, por su tiempo y dedicación para corregir el manuscrito final y fungir como miembros del jurado evaluador.

A mis padres Flor Torres Ramírez y Víctor Sánchez Lerma por brindarme su amor, apoyo y comprensión y que a pesar de la distancia siempre estuvieron conmigo.

A mis hermanas Flor Maribel Sánchez Torres y Viridiana Sánchez Torres por su ejemplo, quienes me enseñaron que con el trabajo y perseverancia se encuentra el éxito profesional.

A mis amigos de Durango que aún a la distancia siempre estuvieron alentándome y apoyándome en todos mis desvelos.

A todos mis compañeros y amigos de la maestría quienes hicieron más agradables las largas horas de estudio durante la maestría.

Finalmente a todas aquellas personas que de una u otra manera me ayudaron durante mi estancia en el posgrado y durante la elaboración de esta tesis.

Esto es posible gracias a todos ustedes.





# Resumen

---

El organismo humano es sumamente complejo y es notable que a pesar de deteriorarse con los años, en algunos casos sigue funcionando bien durante aproximadamente 100 años. Sin embargo, todavía más notable es que dentro de esa enorme complejidad del organismo, el cerebro sobresale precisamente por ser más complejo que los demás, se dice que con sus aproximadamente 100 mil millones de neuronas y un millón de millones de conexiones, es la estructura más compleja que existe en el universo conocido (Ramón et al.).

Los animales y seres humanos contamos con un sistema nervioso, en el cual el cerebro es un órgano muy importante que forma parte de él, para este trabajo nos centraremos en el de los seres humanos que tiene dos funciones principales, la primera se encarga de controlar y coordinar a los demás órganos del cuerpo, esto le permite mantener saludable el organismo mientras efectúa la segunda función que es la encargada de relacionarnos con el medio ambiente, es decir poder recibir señales del mundo exterior.

El conocimiento del cerebro humano avanza lentamente, en parte porque generalmente sólo se estudia en forma directa en personas que han muerto y aunque eso ha proporcionado una gran cantidad de conocimientos sobre las bases de varios problemas médicos, no ha facilitado el conocimiento anatómico o fisiológico de regiones poco conocidas (Ramón et al.).

La comprensión de todos estos conocimientos es muy importante para poder estudiar más a fondo el funcionamiento del cerebro y de ese modo poder elegir e incorporar actividades que ayudan a mejorar nuestras capacidades cerebrales, es decir, vincular las ciencias del aprendizaje con la investigación del cerebro que permita enlazar los avances de la comprensión del aprendizaje humano con la materia educativa.

Las neuronas del cerebro también mueren. Estas células mueren tras completar su ciclo natural de vida, por envejecimiento, o debido a lesiones cerebrales y enfermedades neurodegenerativas (Anabel, 2006).

La lesión cerebral tras sufrir un paro cardiorespiratorio a diferencia del coma por traumatismo o por isquemia focal, significa una agresión isquémica global al cerebro. El grado de daño cerebral depende de cuánto dure la interrupción del flujo sanguíneo cerebral. Por eso es esencial reducir al mínimo el tiempo de paro y la reanimación cardiopulmonar.

Tras la reanudación de la circulación espontánea hay un período transitorio de hiperemia cerebral, seguido de vasoespasmo e hipoperfusión prolongada y multifocal. Los depósitos de oxígeno cerebral y la conciencia se pierden dentro de los 20 segundos del paro cardiorespiratorio, mientras que los depósitos de glucosa y adenosina trifosfato se pierden a los 5 minutos. Sigue una cascada de complejas alteraciones químicas que lleva a la muerte neuronal y culmina en el coma post paro cardiorespiratorio (Cassiani-Miranda et al., 2013).

Hasta la fecha no se conoce un estudio médico donde se pueda observar cómo están distribuidas las conexiones sinápticas de nuestro cerebro, sin embargo es muy sabido que cuando se tiene una lesión cerebral estas conexiones se ven afectadas perdiéndose gran parte de ellas.

En la actualidad existe trabajo en el campo de la simulación del cerebro, en el que se incluyen simulaciones completas y parciales en los cerebros de algunos animales, como por ejemplo los cerebros de las lombrices, moscas y de los ratones (Chalfie et al., 1985).

Sin embargo, tener una simulación del cerebro de los seres humanos resulta complicado debido a que las computadoras actuales no son capaces de reproducir el número masivo de conexiones que se producen en nuestro cerebro.

Anton Arkhipov dijo *“Si tomas un sistema simple como una bala de cañón que sale de un cañón, puedes predecir qué pasará con el lápiz y el papel y unas pocas ecuaciones. Para un sistema complejo como el cerebro, la computadora debe reemplazar la pluma y el papel.”* (Institute, 2019).

Se espera que con ese enfoque se puedan realizar predicciones que informen los experimentos y que permitan comprender mejor los mecanismos de las enfermedades cerebrales. Por ejemplo, una vez que tenga un modelo realista, poder predecir cómo las conexiones neuronales funcionan mal en una enfermedad y cómo responden a posibles tratamientos.

Por lo tanto, el objetivo del presente trabajo es simular el comportamiento de conexión neuronal que requiere un individuo para poder realizar actividades de la vida cotidiana, ejemplo de esto es caminar y sostener un objeto, todo esto se realiza para una persona sana, es decir, que nunca ha sufrido una lesión cerebral y en una persona que sufrió un paro cardiorespiratorio y como consecuencia de esta lesión sufre varias

complicaciones para poder realizar estas actividades.

Es claro que esta simulación es bajo el enfoque de una aproximación a las miles de millones de conexiones que se encuentran en nuestro cerebro. Simulaciones posibles de realizar de acuerdo a las características de los equipos de cómputo con los que contamos.

Para lograr esto, el problema es tratado como un problema de toma de decisiones secuenciales y se usaron redes neuronales artificiales usando aprendizaje por refuerzo, en específico modelos de diferencia temporal para simular la actividad neuronal, los modelos usados fueron, el modelo RMCS (Reward-Modulated Combinatorial Switch) propuesto en (M. Rvachev, 2013) y el modelo BP (Back-Propagation) usando como algoritmo de aprendizaje los modelos de diferencia temporal. En la implementación de cada una de las redes neuronales se añadió un componente de memoria combinatoria Cj con el que se tendrá el control de la memoria de la red neuronal, es decir donde tendremos el registro de las conexiones neuronales, dicho de otra manera donde se contabilizan las conexiones excitatorias o inhibitorias necesarias para poder realizar con éxito las actividades planteadas.

Las complicaciones que tiene el individuo analizado en este trabajo se dan al caminar o al querer sostener un objeto de dimensión pequeña, en cualquiera de los dos casos el individuo sufre de mioclonías leves que le permiten realizar la actividad aunque de manera anormal o mioclonías severas que no le permiten realizar la actividad.

Se plantean los escenarios correspondientes a cada uno de los problemas que el individuo tiene al querer realizar las actividades y con ello se identificaron los elementos del aprendizaje por refuerzo.

En el modelo RMCS (M. Rvachev, 2013) se realizan 251 simulaciones, en cada simulación se generan de manera aleatoria las conexiones neuronales que durante su entrenamiento se reforzarán al obtener una recompensa positiva o se debilitan al obtener una recompensa negativa de acuerdo al objeto presentado y a la acción elegida. Cabe mencionar que para este modelo también se experimentó generando de manera aleatoria el estado inicial de las neuronas, es decir excitatoria o inhibitoria, para esto se usaron varios porcentajes, usando un 10 %, 20 %, 30 %, 40 %, 50 %, 60 %, 70 %, 80 %, 90 % y 100 % de neuronas excitatorias y su complemento como neuronas inhibitorias.

El modelo BP con diferencias temporales se realiza por épocas en su etapa de entrenamiento, al inicio del entrenamiento se genera de manera aleatoria el estado inicial de las neuronas (excitatoria o inhibitoria), la corrección del error entre la predicción y la salida deseada se realiza con el algoritmo de diferencias temporales y en cada época se realiza el registro del componente de memoria combinatoria Cj.



# Índice general

---

<b>Índice de figuras</b>	<b>XV</b>
<b>Índice de tablas</b>	<b>XXIX</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Presentación . . . . .	1
1.2. Hipótesis . . . . .	3
1.3. Objetivos . . . . .	4
1.4. Motivación . . . . .	4
1.5. Planteamiento del problema . . . . .	5
1.6. Antecedentes . . . . .	8
1.7. Metodología . . . . .	9
1.8. Contribuciones . . . . .	10
1.9. Estructura de la tesis . . . . .	12
<b>2. Marco teórico</b>	<b>13</b>
2.1. Biológico . . . . .	13
2.1.1. Sistema nervioso . . . . .	13
2.1.2. La neurona . . . . .	14
2.1.2.1. Anatomía de una neurona . . . . .	14
2.1.2.2. Tipos de neurona . . . . .	15
2.1.2.3. Organización funcional de la neurona . . . . .	16
2.2. Inteligencia artificial y aprendizaje de máquina . . . . .	16
2.2.1. Neurona artificial . . . . .	16
2.2.1.1. Modelo de una Neurona Artificial . . . . .	17
2.2.1.2. Perceptrón . . . . .	18
2.2.2. Redes neuronales artificiales (RNA) . . . . .	19
2.2.2.1. Estructura de las redes neuronales artificiales . . . . .	20
2.2.3. Aprendizaje de las redes neuronales artificiales . . . . .	21
2.2.3.1. Aprendizaje de máquina (Machine Learning) . . . . .	22
2.2.3.2. Algunos métodos de aprendizaje automático . . . . .	22
2.2.4. Aprendizaje por Refuerzo (RL) . . . . .	24
2.2.4.1. Elementos del aprendizaje por refuerzo . . . . .	26

2.2.4.2.	Aprendizaje basado en modelo y libre de modelo . . . . .	28
2.2.4.3.	Interacción Agente-Ambiente . . . . .	29
2.2.5.	Procesos de decisión de Markov (MDPs) . . . . .	30
2.2.5.1.	Políticas y funciones de valor . . . . .	31
2.2.5.2.	Políticas óptimas y funciones de valor óptimas . . . . .	32
2.2.6.	Métodos de solución de aprendizaje por refuerzo . . . . .	33
2.2.6.1.	Programación Dinámica . . . . .	33
2.2.6.2.	Métodos de Monte Carlo . . . . .	34
2.2.6.3.	Diferencias Temporales . . . . .	34
<b>3.</b>	<b>Diseño del experimento</b>	<b>37</b>
3.1.	Modelos propuestos de aprendizaje por refuerzo para redes neuronales . . . . .	37
3.1.1.	Componente de memoria combinatoria Cj . . . . .	39
3.1.2.	Modelo RMCS . . . . .	40
3.1.2.1.	Componentes de la red neuronal . . . . .	41
3.1.2.2.	Regla de aprendizaje del componente Cj . . . . .	42
3.1.2.3.	Algoritmo RMCS (Reward - Modulated Combinatorial Switch) . . . . .	43
3.1.3.	Modelo BP con Diferencias Temporales . . . . .	44
3.1.3.1.	Diferencias temporales para redes neuronales artificiales . . . . .	46
3.1.3.2.	Componentes de la red neuronal . . . . .	49
3.1.3.3.	Regla de aprendizaje del componente Cj . . . . .	50
3.1.3.4.	Algoritmo BP (Back-Propagation) con Diferencias Temporales . . . . .	51
3.2.	Obtención de datos para entrenamiento de las RNA . . . . .	52
3.2.1.	Escenario para el problema: dificultad para caminar . . . . .	52
3.2.1.1.	Identificación de los elementos del aprendizaje por refuerzo . . . . .	53
3.2.1.2.	Definición de objetos de aprendizaje y prueba . . . . .	57
3.2.2.	Escenario para el problema: dificultad con tareas de motricidad fina . . . . .	61
3.2.2.1.	Identificación de los elementos del aprendizaje por refuerzo . . . . .	61
3.2.2.2.	Definición de objetos de aprendizaje y prueba . . . . .	65
3.3.	Validación del modelo RMCS . . . . .	68
3.3.1.	Resultados del problema: Manzanas y Piedras . . . . .	69
<b>4.</b>	<b>Análisis de resultados</b>	<b>77</b>
4.1.	Resumen de entrenamiento de RMCS . . . . .	77
4.2.	Resultados de RMCS . . . . .	82
4.2.1.	Problema: dificultad al caminar . . . . .	91
4.2.1.1.	Análisis de Cj con DBSCAN . . . . .	96
4.2.2.	Problema: dificultad con tareas de motricidad fina . . . . .	98
4.2.2.1.	Análisis de Cj con DBSCAN . . . . .	103

---

4.3. Resumen de entrenamiento de BP con Diferencias Temporales . . . . .	105
4.4. Resultados de BP con diferencias temporales . . . . .	106
4.4.1. Problema: dificultad al caminar . . . . .	107
4.4.2. Problema: dificultad con tareas de motricidad fina . . . . .	108
4.5. Interpretación de resultados . . . . .	109
<b>5. Conclusiones</b>	<b>113</b>
<b>A. Apéndice</b>	<b>119</b>
A.1. Pseudocódigo de algoritmo para el modelo RMCS . . . . .	120
A.2. Pseudocódigo de algoritmo para modelo BP con diferencias temporales .	121
A.3. Código para generar archivos Connections.xlsx para la dificultad para caminar . . . . .	122
A.4. Código para generar archivos SynapticWeights.xlsx para la dificultad para caminar . . . . .	123
A.5. Código para generar archivos Connections.xlsx para la dificultad con tareas de motricidad fina . . . . .	124
A.6. Código para generar archivos SynapticWeights.xlsx para la dificultad con tareas de motricidad fina . . . . .	125
A.7. Análisis del Componente de Memoria Combinatoria Cj . . . . .	126
A.8. README . . . . .	128
A.9. Resultados de RMCS para dificultad al caminar de individuo sano. . . .	139
A.10. Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorespiratorio. . . . .	179
A.11. Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano. . . . .	219
A.12. Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio. . . . .	258
A.13. Resultados de BP con diferencias temporales para dificultad al caminar	297
A.14. Resultados de BP con diferencias temporales para dificultad con tareas de motricidad fina . . . . .	301
<b>Bibliografía</b>	<b>307</b>



# Índice de figuras

---

2.1. Clasificación del Sistema Nervioso. Imagen del usuario OpenStax de Wikipedia (CC BY-SA 4.0), recuperada de <a href="https://es.wikipedia.org/wiki/Archivo:1201_Overview_of_Nervous_System.jpg">https://es.wikipedia.org/wiki/Archivo:1201_Overview_of_Nervous_System.jpg</a> . . . . .	14
2.2. Anatomía de una neurona. Imagen del usuario Acracia de Wikipedia (CC BY-SA 3.0), recuperado de <a href="https://es.wikipedia.org/wiki/Archivo:Neurona.svg">https://es.wikipedia.org/wiki/Archivo:Neurona.svg</a> . . . . .	15
2.3. Modelo de una neurona artificial. . . . .	17
2.4. Estructura del Perceptrón. Imagen del usuario Alejandro Cartas de Wikipedia (CC BY-SA 4.0), recuperada de <a href="https://es.wikipedia.org/wiki/Archivo:Perceptr%C3%B3n.svg">https://es.wikipedia.org/wiki/Archivo:Perceptr%C3%B3n.svg</a> . . . . .	19
2.5. Ejemplo de red neuronal con una capa de entrada, una oculta y una de salida. . . . .	20
2.6. Flujo del Aprendizaje por Refuerzo. Imagen del usuario Megajuce de Wikipedia, traducida al idioma español (CC0 1.0), recuperada de <a href="https://es.wikipedia.org/wiki/Archivo:Reinforcement_learning_diagram.svg">https://es.wikipedia.org/wiki/Archivo:Reinforcement_learning_diagram.svg</a> . . . . .	25
2.7. Interacción Agente-Ambiente en RL. . . . .	29
3.1. Diagrama de Flujo del Modelo RMCS . . . . .	41
3.2. Red Neuronal Artificial para Algoritmo RMCS . . . . .	41
3.3. Diagrama de flujo del aprendizaje del componente $C_j$ para el modelo RMCS . . . . .	43
3.4. Diagrama de Flujo del Modelo BP con Diferencias Temporales . . . . .	46
3.5. Red Neuronal Artificial para Algoritmo de Diferencias Temporales . . . . .	47
3.6. Red Neuronal Artificial para Algoritmo Back-Propagation . . . . .	49
3.7. Diagrama de flujo del aprendizaje de $C_j$ en el modelo BP con diferencias temporales . . . . .	50
3.8. Ejemplo de archivo Connections.xlsx. En la primer columna se indica el número de neurona de la capa oculta o sea del vecindario de sinapsis $N_j$ y en las columnas 2 a la 5 se indica el número de neurona de entrada con la que se está realizando la conexión sináptica en el respectivo vecindario de sinapsis. . . . .	70
3.9. Gráfica del aprendizaje promedio para cada simulación. . . . .	74

## ÍNDICE DE FIGURAS

---

3.10. Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para el problema “Manzanas y Piedras” . . . . .	74
3.11. Histograma de frecuencias para el total de respuestas correctas aprendidas al final de cada simulación para el problema “Manzanas y Piedras”	75
3.12. Porcentajes de aciertos y errores acumulados durante la etapa de aprendizaje en las primeras 60 simulaciones para el problema “Manzanas y Piedras” . . . . .	75
3.13. Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para el problema “Manzanas y Piedras” . . . . .	76
4.1. Ejemplo del contenido en el archivo Connections.xlsx. En la primer columna se indica el número de neurona de la capa oculta o sea del vecindario de sinapsis $N_j$ y en las columnas 2 a la 5 se indica el número de neurona de entrada con la que se está realizando la conexión sináptica en el respectivo vecindario de sinapsis. . . . .	79
4.2. Ejemplo del contenido en el archivo SynapticWeights.xlsx . . . . .	80
4.3. Ejemplos de gráficos donde se registra el aprendizaje promedio en cada simulación y con esto se obtiene el aprendizaje promedio total. . . . .	82
4.4. Ejemplos de gráficos donde se observan distintos comportamientos de aprendizaje. . . . .	85
4.5. Porcentajes de aciertos y errores acumulados durante la etapa de aprendizaje en las primeras 60 simulaciones para el problema “Dificultad al caminar” . . . . .	87
4.6. Parte del archivo del análisis de la memoria combinatoria. Las columnas en color azul hacen referencia a las conexiones involucradas con la neurona de salida correspondiente a la respuesta correcta. . . . .	88
4.7. Parte del archivo con las frecuencias obtenidas de los archivos Connections.xlsx. . . . .	89
4.8. Parte del archivo con las frecuencias obtenidas de los archivos SynapticWeights.xlsx. . . . .	89
4.9. Gráficas de las frecuencias de las conexiones y sus pesos sinápticos, es decir conexión excitatoria o inhibitoria. . . . .	90
4.10. Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano en el problema de dificultad al caminar. . . . .	91
4.11. Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio en el problema de dificultad al caminar.	93
4.12. Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano y uno que sufrió un paro cardiorrespiratorio en el problema de dificultad al caminar. . . . .	94

4.13. Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano en el problema de dificultad con tareas de motricidad fina. . . . .	98
4.14. Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio en el problema de dificultad con tareas de motricidad fina. . . . .	100
4.15. Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano y uno que sufrió un paro cardiorrespiratorio en el problema de dificultad al caminar. . . . .	101
A.1. Formato de archivo contenido en “Memoria Combinatoria”. . . . .	130
A.2. Formato de archivo contenido en “Resultados Aprendizaje” para “Apple and Stone”. . . . .	131
A.3. Formato de archivo contenido en “Resultados Aprendizaje” para “Obstacles”. . . . .	131
A.4. Formato de archivo contenido en “Resultados Aprendizaje” para “Objects”. . . . .	132
A.5. Contenido de las carpetas donde se contienen las gráficas y resumen del aprendizaje. . . . .	133
A.6. Formato de gráficas para aprendizaje. . . . .	133
A.7. Contenido de la carpeta “Aprendizaje Promedio”. . . . .	134
A.8. Contenido de la carpeta “Aprendizaje Promedio”. . . . .	134
A.9. Parte del archivo del análisis de la memoria combinatoria. . . . .	135
A.10. Parte del archivo “Resumen”. . . . .	136
A.11. Parte del archivo “Clasificación Comportamiento Estable”. . . . .	137
A.12. Contenido de las carpetas “BP Alpha 0.005” y “BP Alpha 0.85535”. . . . .	138
A.13. Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_10-90. . . . .	139
A.14. Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_10-90. . . . .	140
A.15. Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_10-90. . . . .	140
A.16. Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_10-90. . . . .	141
A.17. Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_10-90. . . . .	141
A.18. Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_20-80. . . . .	143
A.19. Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_20-80. . . . .	144

## ÍNDICE DE FIGURAS

---

A.20.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_20-80. . . . .	144
A.21.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_20-80. . . . .	145
A.22.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_20-80. . . . .	145
A.23.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_30-70. . . . .	147
A.24.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_30-70. . . . .	148
A.25.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_30-70. . . . .	148
A.26.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_30-70. . . . .	149
A.27.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_30-70. . . . .	149
A.28.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_40-60. . . . .	151
A.29.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_40-60. . . . .	152
A.30.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_40-60. . . . .	152
A.31.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_40-60. . . . .	153
A.32.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_40-60. . . . .	153
A.33.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_50-50. . . . .	155
A.34.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_50-50. . . . .	156
A.35.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_50-50. . . . .	156
A.36.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_50-50. . . . .	157
A.37.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_50-50. . . . .	157
A.38.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_60-40. . . . .	159

A.39.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_60-40. . . . .	160
A.40.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_60-40. . . . .	160
A.41.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_60-40. . . . .	161
A.42.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_60-40. . . . .	161
A.43.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_70-30. . . . .	163
A.44.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_70-30. . . . .	164
A.45.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_70-30. . . . .	164
A.46.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_70-30. . . . .	165
A.47.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_70-30. . . . .	165
A.48.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_80-20. . . . .	167
A.49.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_80-20. . . . .	168
A.50.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_80-20. . . . .	168
A.51.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_80-20. . . . .	169
A.52.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_80-20. . . . .	169
A.53.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_90-10. . . . .	171
A.54.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_90-10. . . . .	172
A.55.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_90-10. . . . .	172
A.56.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_90-10. . . . .	173
A.57.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_90-10. . . . .	173

## ÍNDICE DE FIGURAS

---

A.58.Gráfica del aprendizaje promedio para cada simulación de PNormal_Obstacles_100-0. . . . .	175
A.59.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_100-0. . . . .	176
A.60.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Obstacles_100-0. . . . .	176
A.61.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Obstacles_100-0. . . . .	177
A.62.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Obstacles_100-0. . . . .	177
A.63.Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_10-90. . . . .	179
A.64.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_10-90. . . . .	180
A.65.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_10-90. . . . .	180
A.66.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_10-90. . . . .	181
A.67.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_10-90. . . . .	181
A.68.Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_20-80. . . . .	183
A.69.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_20-80. . . . .	184
A.70.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_20-80. . . . .	184
A.71.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_20-80. . . . .	185
A.72.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_20-80. . . . .	185
A.73.Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_30-70. . . . .	187
A.74.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_30-70. . . . .	188
A.75.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_30-70. . . . .	188
A.76.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_30-70. . . . .	189

A.77.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_30-70. . . . .	189
A.78.Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_40-60. . . . .	191
A.79.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_40-60. . . . .	192
A.80.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_40-60. . . . .	192
A.81.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_40-60. . . . .	193
A.82.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_40-60. . . . .	193
A.83.Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_50-50. . . . .	195
A.84.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_50-50. . . . .	196
A.85.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_50-50. . . . .	196
A.86.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_50-50. . . . .	197
A.87.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_50-50. . . . .	197
A.88.Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_60-40. . . . .	199
A.89.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_60-40. . . . .	200
A.90.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_60-40. . . . .	200
A.91.Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_60-40. . . . .	201
A.92.Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_60-40. . . . .	201
A.93.Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_70-30. . . . .	203
A.94.Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_70-30. . . . .	204
A.95.Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_70-30. . . . .	204

## ÍNDICE DE FIGURAS

---

A.96.	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_70-30. . . . .	205
A.97.	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_70-30. . . . .	205
A.98.	Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_80-20. . . . .	207
A.99.	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_80-20. . . . .	208
A.100.	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_80-20. . . . .	208
A.101.	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_80-20. . . . .	209
A.102.	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_80-20. . . . .	209
A.103.	Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_90-10. . . . .	211
A.104.	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_90-10. . . . .	212
A.105.	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_90-10. . . . .	212
A.106.	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_90-10. . . . .	213
A.107.	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_90-10. . . . .	213
A.108.	Gráfica del aprendizaje promedio para cada simulación de PPCR_Obstacles_100-0. . . . .	215
A.109.	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Obstacles_100-0. . . . .	216
A.110.	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Obstacles_100-0. . . . .	216
A.111.	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Obstacles_100-0. . . . .	217
A.112.	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Obstacles_100-0. . . . .	217
A.113.	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_10-90. . . . .	219
A.114.	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Objects_10-90. . . . .	220

A.115	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_10-90. . . . .	220
A.116	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_10-90. . . . .	221
A.117	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_20-80. . . . .	222
A.118	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_20-80. . . . .	223
A.119	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_20-80. . . . .	223
A.120	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_20-80. . . . .	224
A.121	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_20-80. . . . .	224
A.122	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_30-70. . . . .	226
A.123	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_30-70. . . . .	227
A.124	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_30-70. . . . .	227
A.125	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_30-70. . . . .	228
A.126	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_30-70. . . . .	228
A.127	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_40-60. . . . .	230
A.128	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_40-60. . . . .	231
A.129	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_40-60. . . . .	231
A.130	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_40-60. . . . .	232
A.131	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_40-60. . . . .	232
A.132	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_50-50. . . . .	234
A.133	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_50-50. . . . .	235
A.134	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_50-50. . . . .	235

## ÍNDICE DE FIGURAS

---

A.135	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_50-50. . . . .	236
A.136	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_50-50. . . . .	236
A.137	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_60-40. . . . .	238
A.138	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_60-40. . . . .	239
A.139	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_60-40. . . . .	239
A.140	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_60-40. . . . .	240
A.141	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_60-40. . . . .	240
A.142	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_70-30. . . . .	242
A.143	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_70-30. . . . .	243
A.144	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_70-30. . . . .	243
A.145	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_70-30. . . . .	244
A.146	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_70-30. . . . .	244
A.147	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_80-20. . . . .	246
A.148	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_80-20. . . . .	247
A.149	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_80-20. . . . .	247
A.150	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_80-20. . . . .	248
A.151	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_80-20. . . . .	248
A.152	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_90-10. . . . .	250
A.153	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_90-10. . . . .	251

A.154	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_90-10. . . . .	251
A.155	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_90-10. . . . .	252
A.156	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_90-10. . . . .	252
A.157	Gráfica del aprendizaje promedio para cada simulación de PNormal_Objects_100-0. . . . .	254
A.158	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal_Obstacles_100-0. . . . .	255
A.159	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal_Objects_100-0. . . . .	255
A.160	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal_Objects_100-0. . . . .	256
A.161	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal_Objects_100-0. . . . .	256
A.162	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_10-90. . . . .	258
A.163	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_10-90. . . . .	259
A.164	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_10-90. . . . .	259
A.165	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_10-90. . . . .	260
A.166	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_20-80. . . . .	261
A.167	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_20-80. . . . .	262
A.168	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_20-80. . . . .	262
A.169	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_20-80. . . . .	263
A.170	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_20-80. . . . .	263
A.171	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_30-70. . . . .	265
A.172	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_30-70. . . . .	266
A.173	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_30-70. . . . .	266

## ÍNDICE DE FIGURAS

---

A.174	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_30-70. . . . .	267
A.175	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_30-70. . . . .	267
A.176	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_40-60. . . . .	269
A.177	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_40-60. . . . .	270
A.178	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_40-60. . . . .	270
A.179	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_40-60. . . . .	271
A.180	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_40-60. . . . .	271
A.181	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_50-50. . . . .	273
A.182	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_50-50. . . . .	274
A.183	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_50-50. . . . .	274
A.184	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_50-50. . . . .	275
A.185	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_50-50. . . . .	275
A.186	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_60-40. . . . .	277
A.187	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_60-40. . . . .	278
A.188	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_60-40. . . . .	278
A.189	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_60-40. . . . .	279
A.190	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_60-40. . . . .	279
A.191	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_70-30. . . . .	281
A.192	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_70-30. . . . .	282

A.193	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_70-30. . . . .	282
A.194	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_70-30. . . . .	283
A.195	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_70-30. . . . .	283
A.196	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_80-20. . . . .	285
A.197	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_80-20. . . . .	286
A.198	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_80-20. . . . .	286
A.199	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_80-20. . . . .	287
A.200	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_80-20. . . . .	287
A.201	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_90-10. . . . .	289
A.202	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_90-10. . . . .	290
A.203	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_90-10. . . . .	290
A.204	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_90-10. . . . .	291
A.205	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_90-10. . . . .	291
A.206	Gráfica del aprendizaje promedio para cada simulación de PPCR_Objects_100-0. . . . .	293
A.207	Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR_Objects_100-0. . . . .	294
A.208	Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR_Objects_100-0. . . . .	294
A.209	Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR_Objects_100-0. . . . .	295
A.210	Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR_Objects_100-0. . . . .	295
A.211	Predicciones para PNormal_Obstacles con $\alpha = 0.005$ . . . . .	298
A.212	Predicciones para PPCR_Obstacles con $\alpha = 0.005$ . . . . .	299
A.213	Predicciones para PNormal_Obstacles con $\alpha = 0.85535$ . . . . .	300

## ÍNDICE DE FIGURAS

---

A.214	Predicciones para PPCR_Obstacles con $\alpha = 0.85535$ . . . . .	301
A.215	Predicciones para PNormal_Objects con $\alpha = 0.005$ . . . . .	302
A.216	Predicciones para PPCR_Objects con $\alpha = 0.005$ . . . . .	303
A.217	Predicciones para PNormal_Objects con $\alpha = 0.85535$ . . . . .	304
A.218	Predicciones para PPCR_Objects con $\alpha = 0.85535$ . . . . .	305

# Índice de tablas

---

3.1. Características de los obstáculos . . . . .	54
3.2. Recompensas de aprendizaje para dificultad al caminar para BP con Diferencias Temporales. . . . .	56
3.3. Recompensas de aprendizaje y acciones de prueba correctas para persona normal. . . . .	56
3.4. Recompensas de aprendizaje y acciones de prueba correctas para persona que ha sufrido un paro cardiorrespiratorio. . . . .	57
3.5. Definición de las neuronas de entrada para obstáculos. . . . .	58
3.6. Definición de las neuronas de salida para obstáculos. . . . .	59
3.7. Obstáculos para etapa de aprendizaje. . . . .	60
3.8. Obstáculos para etapa de prueba. . . . .	60
3.9. Características de los objetos . . . . .	62
3.10. Recompensas de aprendizaje para dificultad con tareas de motricidad fina para BP con Diferencias Temporales. . . . .	64
3.11. Recompensas de aprendizaje y acciones de prueba correctas para persona normal. . . . .	64
3.12. Recompensas de aprendizaje y acciones de prueba correctas para persona que sufrió un paro cardiorrespiratorio. . . . .	64
3.13. Definición de las neuronas de entrada para objetos. . . . .	66
3.14. Definición de las neuronas de salida para objetos. . . . .	66
3.15. Objetos para etapa de aprendizaje. . . . .	67
3.16. Objetos para etapa de prueba. . . . .	68
4.1. Intervalos de clase para histograma de frecuencias del aprendizaje promedio obtenido en cada simulación. . . . .	83
4.2. Conteo total de clasificación del aprendizaje para dificultad para caminar. . . . .	95
4.3. Resultados DBSCAN para individuo sano y uno que sufrió un paro cardiorrespiratorio en dificultad al caminar. . . . .	97
4.4. Conteo total de clasificación del aprendizaje para dificultad con tareas de motricidad fina. . . . .	102
4.5. Resultados DBSCAN para individuo sano y uno que sufrió un paro cardiorrespiratorio en dificultad con tareas de motricidad fina. . . . .	104

## ÍNDICE DE TABLAS

---

4.6. Resultados de BP con diferencias temporales para dificultad al caminar, tomando $\alpha = 0.005$ . . . . .	108
4.7. Resultados de BP con diferencias temporales para dificultad al caminar, tomando $\alpha = 0.85535$ . . . . .	108
4.8. Resultados de BP con diferencias temporales para dificultad con tareas de motricidad fina, tomando $\alpha = 0.005$ . . . . .	108
4.9. Resultados de BP con diferencias temporales para dificultad con tareas de motricidad fina, tomando $\alpha = 0.85535$ . . . . .	109

---

## Capítulo 1

# Introducción

---

### 1.1. Presentación

Hay cien mil millones de neuronas en el cerebro humano (Ramón et al.), haciendo y rehaciendo conexiones, ayudándonos con las matemáticas, a encontrar las llaves, ayudándonos a recordar la voz de papá, tomando decisiones, trabajando duro todo el tiempo.

Desde hace años, los especialistas en neurociencia tratan de encontrar la zona en la que se toman decisiones en nuestro cerebro. Nuestra capacidad para tomar decisiones complejas, de vida o muerte, depende de estructuras cerebrales.

La investigación realizada hasta la fecha ha conseguido determinar que la corteza prefrontal juega un papel clave en la toma de decisiones. Esta región del cerebro, y en particular, el lóbulo prefrontal derecho, trabaja en el procesamiento de datos necesario para cualquier elección. El hipocampo, relacionado con la memoria, también es importante en este tipo de tareas (Bernardo, 2016).

La comprensión de todos estos conocimientos es muy importante para poder estudiar más a fondo el funcionamiento del cerebro y de ese modo poder elegir e incorporar actividades que ayudan a mejorar nuestras capacidades cerebrales, es decir, vincular las ciencias del aprendizaje con la investigación del cerebro que permita enlazar los avances de la comprensión del aprendizaje humano con la materia educativa.

Así que cuando el cerebro falla, requiere un gran trabajo de reconexión y no hay margen para errores.

La toma de decisiones es fundamental para cualquier actividad humana, es probable que al tomar tantas, algunas ya parezcan automáticas. Distintas regiones del cerebro son las que participan en la toma de decisiones ya sean correctas o erróneas, además

## 1. INTRODUCCIÓN

---

determina cuales de ellas se almacenarán en la memoria.

Modelar cualquier situación en la que la toma de decisiones se vea involucrada consta de las siguientes etapas (del Carmen):

- La identificación de un problema: Todo proceso de toma de decisiones comienza con un problema.
- La identificación de los criterios para la toma de decisiones: Cada persona que toma decisiones suele tener unos criterios que los guían en su decisión. Este paso nos indica que son tan importantes los criterios que se identifican como los que no.
- La asignación de ponderaciones a los criterios: Todos los criterios seleccionados no tiene la misma importancia, por lo tanto, es necesario ponderar.
- El desarrollo de alternativas: Consiste en la obtención de todas las alternativas que puedan tener éxito para la resolución del problema.
- Análisis de las alternativas: Una vez que se han desarrollado las alternativas se deben analizar cuidadosamente. Las fortalezas y debilidades se vuelven evidencias.
- Selección de una alternativa: Seleccionar la mejor alternativa de todas las valoradas.
- La evaluación de la efectividad de la decisión: Juzga el proceso del resultado de la toma de decisiones.

El campo del aprendizaje por refuerzo (RL, por sus siglas en inglés “Reinforcement Learning”) es una clase del campo del aprendizaje automático que resuelve el problema de la toma de decisiones secuenciales, lo hace mediante un agente que debe aprender a comportarse en un entorno, donde recibe una señal de recompensas numéricas retrasadas. El aprendizaje por refuerzo se puede ver originado por dos ideas principales: la idea de aprendizaje por ensayo y error que comenzó en la psicología del aprendizaje animal y el problema del control óptimo y su solución mediante funciones de valor y programación dinámica (Wiering Marco, 2012).

Una rama importante de la teoría de RL son los modelos de diferencia temporal (TD, por sus siglas en inglés “Temporal Difference”) para la actividad de las neuronas de dopamina. Se cree que la actividad de la dopamina codifica una señal de error de predicción de recompensa (RPE, por sus siglas en inglés “Reward Prediction Error”) que guía el aprendizaje en la corteza frontal y los ganglios basales (M. Rvachev, 2013).

Para resolver el problema de la toma de decisiones instantáneas tomamos como referencia el modelo RMCS (Reward-Modulated Combinatorial Switch) propuesto por (M. Rvachev, 2013), modelo que resuelve el problema de la toma de decisiones por parte

de un agente que recibe recompensas inmediatas dentro de un marco de tipo RL basado en un paradigma de aprendizaje por prueba y error en el que la señal de recompensa modula la memoria en neuronas que actúan como interruptores combinatorios.

El funcionamiento en la etapa de aprendizaje del modelo RMCS (M. Rvachev, 2013) se resume a activar y desactivar cada una de las neuronas, en otras palabras se hacen o eliminan conexiones neuronales de acuerdo a las recompensas obtenidas al elegir una acción, este proceso es llevado a cabo por simulaciones, donde en cada simulación se genera una conexión neuronal inicial de manera aleatoria. En cada simulación son presentados objetos u obstáculos donde el objetivo es que aprenda a elegir la acción correcta de acuerdo al objeto u obstáculo presentado, luego en la etapa de prueba es registrado este aprendizaje a modo de cantidad de aciertos y errores cometidos al presentarle nuevos objetos u obstáculos. Todos los cambios en las conexiones son registrados en un componente de memoria llamado Cj.

En el modelo propuesto no se incluyen funciones de valor y es más parecido a los algoritmos de búsqueda de políticas en el espacio, que a los algoritmos de tipo función-valor. Aunque el algoritmo RMCS (M. Rvachev, 2013) es simple, sugiere que el aprendizaje en el marco de conmutación combinatoria modulada por recompensa puede ser bastante eficiente.

Sin embargo, también se cuenta con otros modelos, por ejemplo el BP (Back-Propagation), que aunque es conocido en el campo del aprendizaje supervisado, usando como algoritmo de aprendizaje los modelos de diferencia temporal, BP se convierte también en un modelo de aprendizaje por refuerzo.

Para este trabajo, se propone usar los dos modelos, RMCS (M. Rvachev, 2013) y BP con diferencias temporales, la razón que justifica el porqué se implementarán los dos modelos es que las características de implementación para cada uno de los dos modelos son diferentes, es decir, en el modelo RMCS (M. Rvachev, 2013) se tienen limitaciones entre las conexiones de neuronas debido al alto costo computacional que se tiene al elevar el número de conexiones. Sin embargo, esas limitaciones se resuelven con el modelo BP, tomando en cuenta que de acuerdo a su funcionamiento se puede hacer uso de herramientas como la biblioteca de Tensorflow, usada en aprendizaje automático con las que se puede disminuir el costo computacional en comparación con el del modelo RMCS (M. Rvachev, 2013).

## 1.2. Hipótesis

- Las conexiones sinápticas inhibitorias se refiere a conexiones débiles que dificultan la aparición del potencial de acción por lo que no se pueden desempeñar las actividades motoras de una manera correcta.

- El número de conexiones sinápticas excitatorias es mayor en un individuo sano que en uno que sufrió un paro cardiorespiratorio.

### 1.3. Objetivos

#### **Objetivo General:**

Realizar simulaciones computacionales de una aproximación de las conexiones neuronales que requiere un individuo al realizar actividades de la vida cotidiana después de haber sufrido un paro cardiorespiratorio, analizar y comparar resultados con el de una persona sana.

#### **Objetivos Particulares:**

1. Usar herramientas de Aprendizaje de Máquina, específicamente Aprendizaje por Refuerzo y Redes Neuronales Artificiales.
2. Implementar los modelos de redes neuronales artificiales:
  - Modelo RMCS (Reward-Modulated Combinatorial Switch)
  - Modelo Back-Propagation, usando el algoritmo de Diferencias Temporales para la actualización de los pesos.
3. Añadir a las redes neuronales un componente de memoria combinatoria cuyo objetivo es almacenar la información sobre el comportamiento de conexión neuronal al presentarse diferentes patrones de entrada, durante la etapa de entrenamiento.
4. Usar la red ya entrenada con los diferentes modelos en diferentes aplicaciones de la vida real en que la toma de decisiones está involucrada (dificultad para caminar, dificultad con tareas de motricidad fina).

### 1.4. Motivación

La principal motivación que llevó a realizar este trabajo de investigación es un motivo personal, mi padre Víctor Sánchez Lerma hace poco más de 9 años sufrió un paro cardiorespiratorio mientras se le practicaba una cirugía de extirpación laparoscópica de la vesícula biliar. Se le practicó reanimación cardiopulmonar durante 5 minutos, tiempo suficientemente largo para dejar en él varias secuelas.

Durante todo este tiempo hemos consultado todo tipo de médicos especialistas sin tener resultados favorables.

Cada uno de los problemas planteados en este trabajo corresponden a las secuelas que mi padre sufre posterior al paro cardiorespiratorio, después de intentar encontrar

una cura tratando con muchos especialistas y no conseguir ningún resultado, me propuse a entender y analizar el daño que sufrió el cerebro de mi padre ante la falta de oxígeno.

Hoy en día, la neurociencia proporciona una nueva manera de acercarse a la comprensión de los mecanismos que regulan el control de las reacciones nerviosas y del comportamiento del cerebro. Los avances que se tienen a la fecha de esta ciencia son impresionantes, sin embargo, aún no se conoce alguno que pueda servir para curar definitivamente las secuelas de un paro cardiorespiratorio.

Aunque este trabajo se basa únicamente en las secuelas de una persona que sufrió un paro cardiorespiratorio, la técnica presentada puede ser más general y puede ser la puerta para en un futuro poder tratar más enfermedades, esperando poder realizar predicciones que informen los experimentos y que permitan comprender mejor los mecanismos de las enfermedades cerebrales. Teniendo un modelo realista podremos predecir cómo las conexiones neuronales funcionan mal ante una enfermedad y cómo responderían a los múltiples tratamientos.

Se que aún estoy lejos de poder encontrar esa cura pero no desistiré en este proyecto que principalmente es personal hasta encontrar una respuesta satisfactoria que pueda ayudar a que mi padre retome su vida de manera normal.

## 1.5. Planteamiento del problema

Nuestro cerebro es responsable de la toma de miles de decisiones instantáneas, meditadas o no.

Las células cerebrales utilizan impulsos eléctricos para comunicarse entre sí y guiar funciones que van desde el ritmo cardiaco y respiratorio hasta la toma de decisiones (Dan, 2019) .

Gracias a la plasticidad, que hace referencia a la capacidad que posee el cerebro para cambiar respondiendo a las modificaciones del entorno, este mecanismo opera de varias maneras a nivel de las conexiones sinápticas, algunas sinapsis pueden ser generadas y otras eliminadas.

Es así que el cerebro humano responde con ésta plasticidad en las relaciones con otras personas y va asimilando aquello a lo que está expuesto, por esto, modifica su organización y funcionamiento con el fin de captar la abundancia de estímulos que le muestra el mundo actual. Las huellas dejadas por el aprendizaje y la memorización son el fruto de las modificaciones en las conexiones sinápticas (OECD, 2007).

Dada la distribución adecuada de las conexiones neuronales, las neuronas pueden

## 1. INTRODUCCIÓN

---

procesar información y cambiar la salida de la neurona en función de las combinaciones de neuronas de entrada que se encuentren activas.

La neurona aprende a ser más propensa a generar un pico eléctrico (spikes) o también conocido como potencial de acción dadas las combinaciones de neuronas de disparo para las cuales un spike anterior de la neurona había generado una señal de recompensa global positiva, que en términos biológicos ésta señal puede estar mediada por ciertas hormonas moduladoras o ciertos neurotransmisores.

Sin embargo las neuronas del cerebro también mueren. Estas células mueren tras completar su ciclo natural de vida, por envejecimiento, o debido a lesiones cerebrales y enfermedades neurodegenerativas (Anabel, 2006).

La lesión cerebral tras sufrir un paro cardiorespiratorio incluye la pérdida de la integridad celular que dispara la liberación de glutamato generando excitotoxicidad (proceso patológico por el cual las neuronas son dañadas y destruidas por las sobre-activaciones de receptores del neurotransmisor excitatorio glutamato) asociada a la disminución de los neurotransmisores moduladores y la elevación del calcio intracelular provocando lesiones en diferentes áreas cerebrales causando síntomas cognitivos con un impacto significativo en la calidad de vida de las personas (Cassiani-Miranda et al., 2013).

Los pacientes pueden sufrir hemiplejía, convulsiones, ataxia, mioclonías, o cambios mentales permanentes como secuelas al paro cardiorespiratorio.

De acuerdo al diccionario de medicina (Press, 2007):

La hemiplejia es un trastorno del cuerpo del paciente en el que la mitad de su cuerpo está paralizada.

Las convulsiones ocurren por la aparición repentina de una actividad eléctrica anormal en el cerebro.

La ataxia describe una falta de control muscular o coordinación de los movimientos voluntarios, como caminar o levantar objetos. La ataxia puede afectar varios movimientos y provocar dificultades para hablar, mover los ojos y tragar.

Es un signo de diversos trastornos neurológicos que puede provocar:

- Falta de coordinación
- Andar inestable y tendencia a tropezar
- Dificultad para caminar

- Dificultad con tareas de motricidad fina, como comer, escribir o abotonarse una camisa
- Cambios en el habla
- Movimientos involuntarios de los ojos hacia adelante y hacia atrás (Nistagmo)
- Dificultad para tragar

Las mioclonías forman parte de un grupo de enfermedades de trastornos del movimiento, caracterizadas por un exceso de movimientos (movimientos anormales involuntarios). Son movimientos rápidos, muy breves y de amplitud variable producidos por contracción simultánea de músculos (mioclonías positivas) o inhibición del tono muscular (mioclonías negativas o asterixis).

Las mioclonías afectan, sobre todo, a las extremidades superiores, aumentan con los movimientos voluntarios y mejoran con la ingesta de alcohol.

Para este trabajo nos planteamos simular, comprender y analizar el comportamiento de conexión neuronal en el cerebro de una persona que ha sufrido una lesión cerebral y para esto debemos tomar en cuenta la conexión neuronal que se tenía antes de la lesión, es decir, cuando la persona se encontraba en perfecta salud.

El paciente tomado para ser analizado durante la realización de este trabajo sufre específicamente de mioclonías y ataxia tras haber sufrido un paro cardiorespiratorio desde hace nueve años, entre las principales dificultades que presenta se encuentran:

#### **Dificultad para caminar**

El paciente presenta dificultad para caminar sin apoyo, al observar algún obstáculo por más mínimo que sea durante su recorrido sufre de mioclonías que le impiden dar el paso.

Las mioclonías aparecen también al percibir auditivamente sonido cercano a él, que represente algún peligro para el paciente, o al percibir visualmente que alguna persona lo está observando.

El paciente se refiere a tener una sensación de miedo que le imposibilita realizar de manera normal la actividad de caminar.

La dificultad para caminar y mioclonías causada por los motivos ya mencionados, desaparecen al momento de recibir apoyo; ya sea tomar al paciente de la mano, apoyo por parte de un objeto como un bastón, o al momento de encontrarse bajos los efectos del alcohol.

#### **Dificultad con tareas de motricidad fina**

## 1. INTRODUCCIÓN

---

La dificultad para realizar tareas de motricidad fina se observan claramente en el paciente en situaciones como:

- Recibir, tomar o dar con su mano un artículo de dimensión pequeña, específicamente al querer sujetar el objeto en cuestión con los dedos pulgar e índice. Los objetos considerados por nuestro estudio son monedas, llaves, insectos, entre otros objetos de dimensión pequeña.
- Abotonarse la camisa.
- Atornillar.

Apoyándonos de las redes neuronales artificiales y del aprendizaje por prueba y error (Aprendizaje por Refuerzo) para simular el funcionamiento del cerebro, se consideran los estados de actividad neuronal binarios (disparar o no disparar) y dada una combinación arbitraria  $X$  de neuronas de disparo en una capa de entrada  $L_1$ , encuentre una combinación de conexiones óptima  $Y(X)$  con la que se obtenga una señal de recompensa global positiva en una capa de salida  $L_2$ .

### 1.6. Antecedentes

Existen diversos trabajos de investigación referentes al cerebro humano, dentro de los trabajos similares o relacionados con el de esta tesis se tiene el de Marat M. Rvachev (M. Rvachev, 2013), el cual se titula “Neuron as a reward-modulated combinatorial switch and a model of learning behavior”, donde el objetivo principal es la de proponer un modelo de aprendizaje para redes neuronales artificiales con las que se puedan solucionar problemas de la toma de decisiones.

En ese trabajo únicamente se plantea el modelo de aprendizaje RMCS, el cual es el que usamos para resolver nuestro problema, sin embargo, en ese trabajo únicamente se realiza una validación del componente Cj relacionándolo con un mecanismo similar al de un músculo, él propone un ejemplo del funcionamiento completo del modelo mediante un problema donde un individuo debe aprender a reconocer una manzana y una roca para comérsela o lanzarla al piso.

La principal diferencia entre ese trabajo y el realizado en esta tesis se debe al objetivo de cada uno, Marat busca un modelo con el que pueda resolver problemas de toma de decisiones y a este modelo añade un componente de memoria combinatoria, el cual tiene relación con las conexiones de la red neuronal artificial y a su vez tiene que ver con las conexiones neuronales del cerebro humano, en esta tesis empleamos su modelo pero deseamos encontrar en los resultados de Cj los modelos de redes neuronales artificiales que nos proporcionan las conexiones neuronales que el individuo requiere para poder realizar ciertas actividades en las que la toma de decisiones se ve involucrada. Es decir,

queremos conocer la conexión sináptica que realizan las neuronas de nuestro cerebro al encontrarse con un problema.

Y finalmente buscamos encontrar una relación entre esas conexiones encontradas para un individuo sano y uno que sufrió un paro cardiorrespiratorio.

Otro de los trabajos similares es el proyecto Blue Brain, el cual tiene como objetivo estudiar la estructura del cerebro creando una simulación de todo el cerebro a nivel molecular. Es el primer intento de ingeniería inversa para conocer el funcionamiento del cerebro. La ingeniería inversa trata de obtener información a partir del producto, en este caso el cerebro, para determinar su composición y la manera en que sus elementos se comportan entre sí (EPFL).

La vía que ha escogido Blue Brain consiste en abordar una pequeña área del cerebro y desarrollar un algoritmo capaz de predecir los patrones de activación de las células nerviosas.

Este trabajo es similar a lo que buscamos hacer con la información obtenida en el componente Cj ya que a partir de la simulación de una aproximación de las conexiones neuronales buscamos encontrar relación entre ellas para poder llevar el trabajo particular a algo más general.

## 1.7. Metodología

La hipótesis principal de éste trabajo es que el problema en el desempeño de las actividades de la vida cotidiana de una persona que sufrió un paro cardiorrespiratorio se desencadena del funcionamiento no adecuado en la producción y comunicación de neurotransmisores entre las neuronas, necesarios para realizar éstas actividades de la vida cotidiana.

Es por eso que se pretende realizar simulaciones computacionales de una aproximación en las conexiones neuronales de una persona bajo esas condiciones y una sana.

Para tratar el problema que se plantea, nos apoyamos del campo de la inteligencia artificial, específicamente de las redes neuronales artificiales con las que podemos representar las conexiones neuronales del cerebro, y del aprendizaje por refuerzo que está basado en la psicología humana.

En aprendizaje por refuerzo, un agente trata de aprender un comportamiento mediante iteraciones de prueba y error, no se le dice qué acción tomar, debe descubrir qué acciones dan el beneficio máximo.

## 1. INTRODUCCIÓN

---

Con cada uno de los nodos de la red neuronal artificial estamos representando a las neuronas y con las conexiones entre esos nodos representamos las conexiones sinápticas de nuestro cerebro. Haciendo uso de la teoría del aprendizaje por refuerzo buscamos encontrar las conexiones sinápticas que logran obtener las recompensas mayores, es decir, las conexiones con las que el individuo realiza cada una de las actividades de la vida diaria de la manera más adecuada de acuerdo a cada una de sus limitaciones.

A cada una de las redes neuronales que usamos para modelar las conexiones neuronales de nuestro cerebro, incorporamos un componente de memoria combinatoria el cual llamamos Cj en el cual se lleva el registro de las conexiones neuronales ya sea excitatorias o inhibitorias. Teniendo este registro podremos comparar las distintas conexiones encontradas con las que se espera que el individuo se desempeñe de manera favorable ante cualquiera de las situaciones planteadas.

Es muy bien sabido dentro de la teoría que cuando se sufre una lesión cerebral se pierden o debilitan conexiones sinápticas que no siempre se regeneran aún con la ayuda de medicamentos y como consecuencia el individuo que sufre la lesión cerebral queda con ciertas secuelas, ya sea motoras, de lenguaje, etc. Al analizar el funcionamiento del modelo RMCS y de la implementación del componente de Cj es que se decide abordar nuestro problema como uno de toma de decisiones, el cual se basa en un paradigma de prueba y error.

Al hacerlo de este modo podremos tener registros en el componente Cj de cómo las conexiones sinápticas se crean o se destruyen, que como ya se mencionó anteriormente, en un individuo con lesión cerebral estas conexiones se ven afectadas. Por lo tanto al realizar las simulaciones computacionales de una aproximación de estas conexiones siguiendo el paradigma de prueba y error podemos notar cómo estas conexiones se comportan mientras se realiza la etapa de aprendizaje.

### 1.8. Contribuciones

La principal contribución de este trabajo es reproducir las conexiones neuronales como una aproximación a las de un cerebro real y tratar de encontrar la conexión que permite a un individuo ya sea sano o con lesión cerebral (paro cardiopulmonar para ser precisos) realizar de manera adecuada las actividades de la vida diaria como caminar o sujetar algún objeto.

Además de hacer uso de las redes neuronales con el fin de comprender el funcionamiento del cerebro, se pretende hacer uso de un componente de memoria combinatoria (llamado componente Cj) con el que se tendrá el control de la memoria de la red neuronal, es decir donde tendremos la información fundamental para este trabajo, en este componente Cj tendremos el registro de las conexiones neuronales, es decir se contabi-

lizan las conexiones excitatorias o inhibitorias.

El resultado del componente Cj junto al aprendizaje de la red neuronal resulta ser el más importante ya que con él podremos analizar la conexión neuronal en un cerebro sano y en un cerebro después de sufrir una lesión cerebral.

Entender el comportamiento de Cj que subyace a las acciones de una persona normal y otra con afectaciones en neuronas motoras nos lleva a recrear comportamientos similares pero diferentes con base en el comportamiento de Cj.

En la actualidad existen avances farmacéuticos capaces de regenerar las conexiones neuronales después de sufrir una lesión cerebral.

Un trabajo de varias instituciones estadounidenses, liderado por investigadores de la Universidad Case Western Reserve, ha descubierto que los fármacos miconazol y clobetasol, utilizados para tratar el pie de atleta y eczemas, respectivamente, son capaces de estimular la regeneración de las células cerebrales dañadas por esclerosis múltiple (AMERICAN).

En el estudio dirigido por Stuart A. Lipton, se muestra que el fármaco, llamado Nitro Memantine, combina dos medicamentos aprobados por la FDA y puede restaurar las sinapsis, que representan las conexiones entre las neuronas que se han perdido durante la progresión de la enfermedad de Alzheimer en el cerebro (Talentova et al.,2013).

Investigadores de la Universidad de Cádiz trabajaron mostrando como una serie de productos naturales a partir de plantas tienen la capacidad para activar una familia de proteínas, llamadas proteínas kinasa de tipo C o PKC. las cuales favorecen la formación de neuronas en el cerebro. Publicaron que compuestos de la familia de los 12-desoxiforbos son capaces de activar PKC y que además no tienen actividad tumoral como otros compuestos que se encuentran en el mercado que activan esta familia de proteínas, pero son altamente tumorigénicos (Geribaldi-Doldán et al.,2016).

Teniendo una simulación de las conexiones neuronales y conociendo los efectos de estos avances farmacéuticos en ellas se puede experimentar de manera computacional el efecto que tendrían de acuerdo a la conexión neuronal que se tenga en el paciente. Con estos tipos de pruebas los pacientes con lesión cerebral tendrían una esperanza más de poder recuperar la mayor parte de las conexiones neuronales perdidas tras el incidente y por ende poder mejorar sus capacidades motoras afectadas.

### 1.9. Estructura de la tesis

El presente trabajo está dividido en IV capítulos, distribuidos de la siguiente manera:

En el capítulo 2 encontramos el marco teórico, es decir las bases tanto biológicas como de inteligencia artificial y aprendizaje de máquina de las que nos apoyamos en este proyecto.

En el capítulo 3 se encuentra el diseño del experimento, es decir en este se encuentra la información de cómo fue empleada la teoría analizada en el capítulo 2 para modelar nuestro problema.

El capítulo 4 consta del análisis de resultados después de realizar el experimento planteado anteriormente.

Finalmente se presentan las conclusiones de este trabajo en el capítulo 5. Además se incluyen los pseudocódigos de los dos modelos de redes neurales empleados y las referencias bibliográficas utilizadas para la elaboración de este trabajo.

---

## Capítulo 2

# Marco teórico

---

En este capítulo se presentan las fuentes de consulta teórica necesarias para la elaboración de este trabajo, se encuentra dividido en dos principales secciones. La primera consta de conceptos biológicos acerca del cerebro y las neuronas del mismo. En la segunda se tiene información relevante de inteligencia artificial y aprendizaje de máquina.

Esto con la finalidad de que el lector pueda comprender la relación existente entre estos dos temas principales y así se facilite la comprensión del tema de investigación que se plantea en esta tesis.


## 2.1. Biológico

### 2.1.1. Sistema nervioso

El sistema nervioso es el que dirige y coordinada todas las funciones del organismo, este sistema está dividido en el Sistema Nervioso Central (SNC), el cual está formado por el encéfalo y la médula espinal, y el Sistema Nervioso Periférico (SNP), formado por los ganglios y los nervios, es el encargado de conectar al sistema nervioso central con los receptores sensoriales (nervios periféricos), es decir los que reciben información proveniente del medio externo e interno, esa información es transmitida por medio de los axones de las células motoras y sensoriales y con ayuda de los músculos se efectúan las decisiones del SNC (Ramón et al.).

El sistema nervioso está compuesto por células llamadas neuronas, estas utilizan señales eléctricas y químicas para conducir impulsos que intercambian información, estas señales viajan largas distancias. Las neuronas transmiten con rapidez la información a otras neuronas o a células efectoras (músculos o glándulas) utilizando neurotransmisores químicos.

En la figura 2.1 se muestra la clasificación del sistema nervioso ya mencionada.



**Figura 2.1:** Clasificación del Sistema Nervioso. Imagen del usuario OpenStax de Wikipedia (CC BY-SA 4.0), recuperada de [https://es.wikipedia.org/wiki/Archivo:1201\\_Overview\\_of\\_Nervous\\_System.jpg](https://es.wikipedia.org/wiki/Archivo:1201_Overview_of_Nervous_System.jpg)

### 2.1.2. La neurona

Una neurona es una célula del tejido nervioso que transmite y procesa señales químicas o eléctricas. Una neurona está conectada con otras neuronas formando una red. Estas se comunican a través de impulsos eléctricos y reacciones químicas.

La neurona se denomina una célula excitable debido a que puede conducir impulsos eléctricos llamados potenciales de acción, que codifican distintos tipos de información motora y sensitiva, estos potenciales de acción pueden ser excitatorios, que se refiere a las señales que provocan que la neurona dispare o pueden ser inhibitorios que tienden a impedir que la neurona dispare. Una neurona tiene un cuerpo celular denominado soma, un axón y las dendritas (Sircar, 2012).

#### 2.1.2.1. Anatomía de una neurona


Las neuronas, como otras células constan de un cuerpo celular llamado soma, un axón y dendritas, en la figura 2.2 se presentan gráficamente cada uno de estos elementos.

En el soma, también conocido como cuerpo celular se encuentra el núcleo de la neurona.

Las dendritas son ramificaciones cortas, estas se derivan en forma extensa justo después de surgir del soma. Las dendritas tienen aspecto “espinoso”, con proyecciones

diminutas numerosas denominadas “espinas”, que existen en su superficie. Las espinas son los puntos de contacto sináptico y se conectan con el tallo principal mediante un cuello delgado y terminan en una cabeza bulbosa. Cada espina forma por lo menos una sinapsis (Sircar, 2012).

El axón es más grueso y largo que las dendritas. En algunas neuronas, el axón puede tener mielina. El axón conduce el potencial de acción, es decir transmite el impulso nervioso generado a grandes distancias y por último la terminal del axón que tiene aspecto similar al de las dendritas y se encarga de realizar la sinapsis con las dendritas de otras neuronas.



**Figura 2.2:** Anatomía de una neurona. Imagen del usuario Acracia de Wikipedia (CC BY-SA 3.0), recuperado de <https://es.wikipedia.org/wiki/Archivo:Neurona.svg>

#### 2.1.2.2. Tipos de neurona

La información dentro del sistema nervioso es manejada por tres tipos de neuronas; las neuronas sensoriales, las interneuronas y las motoneuronas (Ramón et al.).

La función de las neuronas sensoriales es enviar información desde los órganos sensoriales hacia la médula espinal. Al ser procesada esta información por el cerebro es enviada a las interneuronas, las cuales se conectan con otras neuronas pero nunca con los receptores sensoriales o músculos, por lo tanto al ser recibida y procesada la información en estas neuronas, es enviada a las motoneuronas ubicadas en la médula espinal y encargadas de enviar la información a los músculos a través de las fibras musculares.

En otras palabras, las funciones del sistema nervioso se basan en la obtención de información ya sea del exterior o interior de nuestro cuerpo a través de las neuronas sensoriales, esta información es procesada por el cerebro y viaja por la médula espi-

nal a través de las interneuronas y las motoneuronas hasta nuestros músculos donde finalmente se da una respuesta motora.

### 2.1.2.3. Organización funcional de la neurona

La función de recibir y procesar la información recibida del exterior o interior sucede en las dendritas y en el soma. Sin olvidar que las señales que se reciben pueden ser excitatorias o inhibitorias.

Las neuronas reciben muchas señales en todas sus ramificaciones dendríticas. Biológicamente, las neuronas pueden tener 10.000 entradas diferentes (Bell, 2005), que se genere o no un potencial de acción depende de todas las señales excitatorias o inhibitorias que recibe.

Al generarse el potencial de acción, este se conduce por el axón hasta llegar a la nueva neurona, llamada neurona receptora. El axón está cubierto de mielina, la cual ayuda a transmitir el potencial de acción rápidamente.

Las conexiones de neurona a neurona se forman sobre las dendritas y el cuerpo celular de otras neuronas. Estas conexiones son conocidas como sinapsis y es donde se transmite información de la primera neurona también llamada neurona presináptica, a la neurona receptora o también conocida como neurona postsináptica.

De esta forma, el axón y sus terminales desempeñan la función neuronal de enviar información a las células receptoras. Al igual que una sola neurona puede recibir señales de muchas neuronas presinápticas, también se pueden hacer conexiones sinápticas con numerosas neuronas postsinápticas mediante las terminales axónicas.

## 2.2. Inteligencia artificial y aprendizaje de máquina

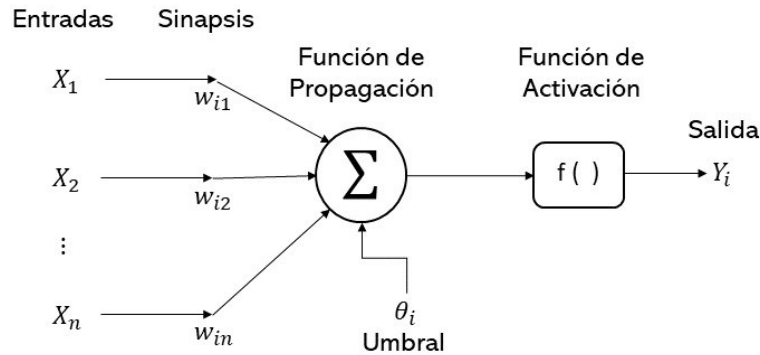
### 2.2.1. Neurona artificial

Una red neuronal artificial es un sistema informático compuesto por una serie de elementos de procesamiento simples, interconectados, que procesan la información por su respuesta de estado dinámico a las entradas externas (Bell, 2005).

Las redes neuronales artificiales están basadas en la arquitectura del cerebro e inspiradas en el comportamiento del cerebro humano, se basan en una información de entrada que es sometida a diversas operaciones produciendo valores de salida.

### 2.2.1.1. Modelo de una Neurona Artificial

Inspirados en el mecanismo biológico, Warren Sturgis McCulloch y Walter Harry Pitts crearon un modelo artificial de una neurona en 1943 conocido como el modelo neuronal McCulloch-Pitts (W.Pitss, 1943).



**Figura 2.3:** Modelo de una neurona artificial.

La neurona artificial consta de los siguientes elementos (W.Pitss, 1943) :

- Conjunto de entradas  $x_j$  y unos pesos sinápticos  $w_{ij}$ , con  $j = 1, \dots, n$ .
- Función de propagación  $h_i$  definida a partir del conjunto de entradas y los pesos sinápticos. Es decir

$$h_i(x_1, \dots, x_n, w_{i1}, \dots, w_{in}) \quad (2.1)$$

la regla de propagación más comúnmente utilizada es:

$$h_i(x_1, \dots, x_n, w_{i1}, \dots, w_{in}) = \sum_{j=1}^n w_{ij}x_j \quad (2.2)$$

El umbral conocido como  $\theta_i$  es un parámetro adicional que suele ser añadido al conjunto de pesos de la neurona, es restado del potencial postsináptico. Es decir:

$$h_i(x_1, \dots, x_n, w_{i1}, \dots, w_{in}) = \sum_{j=1}^n w_{ij}x_j - \theta_i \quad (2.3)$$

- Función de activación, la cual representa a la salida de la neurona y su estado de activación. Si se denota por  $y_i$  dicha función de activación, se tiene:

$$y_i = f_i(h_i) = f_i\left(\sum_{j=1}^n w_{ij}x_j\right) \quad (2.4)$$

Ejemplos de funciones de activación son los siguientes:

1. **Neuronas todo-nada**

En este tipo de neuronas todo-nada, también llamadas dispositivos de umbral, la función  $f_i(\sum_{j=1}^n w_{ij}x_j - \theta_i)$  es una función escalonada. En tal caso se tiene:

$$y_i = \begin{cases} 1, & \text{si } \sum_{j=1}^n w_{ij}x_j \geq \theta_i, \\ 0, & \text{si } \sum_{j=1}^n w_{ij}x_j < \theta_i. \end{cases} \quad (2.5)$$

2. **Neurona continua sigmoidea**

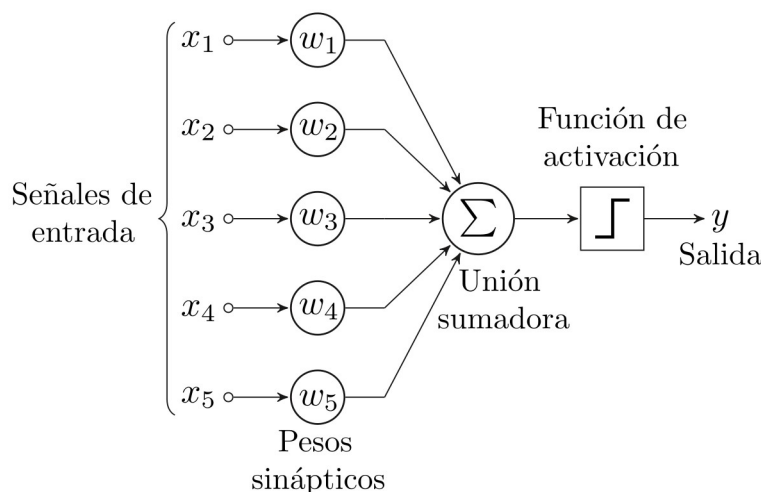
Si queremos obtener una salida continua, es habitual utilizar como función de activación una función sigmoidea. Las funciones sigmoideas más usadas son:

$$y_i = \frac{1}{1 + e^{-\sum_{j=1}^n w_{ij}x_j - \theta_i}}, \text{ con } y_i \in [0, 1] \quad (2.6)$$

$$y_i = \frac{e^{\sum_{j=1}^n w_{ij}x_j - \theta_i} - e^{-\sum_{j=1}^n w_{ij}x_j - \theta_i}}{e^{\sum_{j=1}^n w_{ij}x_j - \theta_i} + e^{-\sum_{j=1}^n w_{ij}x_j - \theta_i}}, \text{ con } y_i \in [-1, 1] \quad (2.7)$$

2.2.1.2. **Perceptrón**

Inspirado en el modelo McCulloch-Pitts (W.Pitts, 1943), Frank Rosenblatt creó una estructura llamada perceptrón en 1962 (Rosenblatt, 1962).



**Figura 2.4:** Estructura del Perceptrón. Imagen del usuario Alejandro Cartas de Wikipedia (CC BY-SA 4.0), recuperada de <https://es.wikipedia.org/wiki/Archivo:Perceptr%C3%B3n.svg>

El perceptrón es la base de una red neuronal. Es bastante simple. Recibe señales de entrada y luego pasa el valor a través de alguna forma de función y finalmente emite el resultado de la función (Bell, 2005).

Visto desde el funcionamiento biológico de las neuronas, las entradas del perceptrón actúan como las dendritas o señales de entrada hacia la neurona. La función de activación realiza el papel del soma que decide si se dispara o no la señal eléctrica y la salida modela al axón que al activarse envía información hacia las neuronas con las cuales se encuentra conectada (Rosenblatt, 1962).

### 2.2.2. Redes neuronales artificiales (RNA)

Una red neuronal artificial consiste de un conjunto de elementos de procesamiento, también conocidos como neuronas, los cuales están unidos por conectores (Olivera). En la figura 2.5 se tiene una red neuronal artificial con una capa de entrada, una oculta y una de salida.

En cada neurona se realiza una función de la forma

$$y_i = f_i(h_i - \theta_i) \quad (2.8)$$

donde


$$h_i = \sum w_{ij}X_j \quad (2.9)$$

y donde  $y_i$  es la salida de la neurona  $i$ ,  $x_j$  es la  $j$ -ésima entrada a la neurona, y  $w_{ij}$  es el peso sináptico de la conexión entre las neuronas  $i$  y  $j$ .  $\theta_i$  es el umbral. Generalmente la función  $f_i$  es no lineal, como ejemplo de esto tenemos a la función sigmoidea.

Cada una de las neuronas se encuentran agrupadas en capas. En cada capa se realiza el procesamiento de sus entradas de la misma manera. A las capas que se encuentran entre la capa de entrada y salida se llaman capas ocultas.

El proceso del funcionamiento de una red neuronal artificial se resume en:

- Un patrón externo conformado por un conjunto de señales se aplica a las neuronas de la capa de entrada.
- Esta información es procesada por cada una de las neuronas de la capa y es generada una señal de salida que son usadas como entrada para las neuronas de la capa siguiente.
- Se repite este proceso hasta que la última capa genere una salida.



**Figura 2.5:** Ejemplo de red neuronal con una capa de entrada, una oculta y una de salida.

### 2.2.2.1. Estructura de las redes neuronales artificiales

Las redes neuronales artificiales se pueden estructurar de acuerdo a las distintas características:

- De acuerdo al número de capas

1. Redes neuronales monocapa:  
Estas redes corresponden a las más sencillas ya que solo constan de una capa, sus conexiones las realiza con las neuronas de esa misma capa.
2. Redes neuronales multicapa:  
Estas redes constan de más de una capa de entrada, una o varias ocultas y una de salida.

■ **De acuerdo al tipo de conexiones**

1. Redes neuronales no recurrentes:  
En estas redes la transferencia de las señales se produce en un mismo sentido, es decir, no existe la posibilidad de conexiones con capas anteriores. Debido a la propagación de la información este tipo de redes neuronales no tienen memoria, ya que no se requiere almacenar información que pueda ser utilizada durante su entrenamiento futuro.
2. Redes neuronales recurrentes:  
A diferencia del caso anterior en este tipo de redes neuronales se tiene la posibilidad de realizar conexiones entre neuronas de distintas capas. Estas conexiones pueden ser entre neuronas de capas anteriores, neuronas de la misma capa o más simple, entre una misma neurona.

■ **De acuerdo al grado de conexión**

1. Redes neuronales totalmente conectadas:  
Para estas redes todas las neuronas de una capa están conectadas con las de la capa siguiente (redes no recurrentes) o con las de la anterior (redes recurrentes).
2. Redes parcialmente conectadas:  
Para este caso no se tiene la conexión total entre neuronas de diferentes capas.

### 2.2.3. Aprendizaje de las redes neuronales artificiales

El proceso de aprendizaje de una red neuronal artificial consiste en la modificación de sus pesos de acuerdo a la información de entrada que se le presente, durante este proceso se crean, modifican o eliminan conexiones.

La creación de una conexión se refiere a los pesos que pasan a tener un valor distinto de cero, en cambio la destrucción hace referencia a los pesos en los cuales su valor pasa a ser cero, mientras que la modificación se da cuando el valor de los pesos cambia pero siempre a un valor distinto de cero.

Al terminar este proceso de aprendizaje, es decir cuando la red ya aprendió, los valores de los pesos se mantienen estables.

Existen dos reglas distintas de aprendizaje, conocidas como aprendizaje OFF LINE y ON LINE.

En el aprendizaje OFF LINE existen un conjunto de datos para la etapa de entrenamiento y uno distinto para la etapa de prueba, donde los pesos finales obtenidos en el proceso de entrenamiento son usados con el conjunto de datos de prueba, mientras que en el aprendizaje ON LINE los pesos varían dinámicamente cada vez que se le presenta nueva información.

Para que una red neuronal “aprenda” se utilizan métodos de aprendizaje de máquina.

### **2.2.3.1. Aprendizaje de máquina (Machine Learning)**

El aprendizaje de máquina o machine learning es una aplicación de inteligencia artificial (AI, por sus siglas en inglés “Artificial Intelligence”) que proporciona a los sistemas la capacidad de aprender y mejorar automáticamente a partir de la experiencia sin ser programado explícitamente.

La definición de aprendizaje de máquina según Tom M. Mitchell en (Bell, 2005) nos dice:

“Se dice que un programa de computadora aprende de la experiencia  $E$  con respecto a alguna clase de tareas  $T$  y la medida de desempeño  $P$ , si su desempeño en tareas en  $T$ , medido por  $P$ , mejora con la experiencia  $E$ ”.

El aprendizaje de máquina se centra en el desarrollo de programas informáticos que pueden acceder a los datos y utilizarlos para aprender por sí mismos.

El objetivo principal del aprendizaje de máquina, es permitir que las computadoras aprendan automáticamente sin intervención o asistencia humana y ajustar las acciones en consecuencia.

### **2.2.3.2. Algunos métodos de aprendizaje automático**

Los métodos de aprendizaje automático se clasifican en: aprendizaje supervisado, no supervisado o por refuerzo.

- **Aprendizaje supervisado**

El aprendizaje supervisado se refiere al trabajo con un conjunto de datos de entrenamiento etiquetados (Bell, 2005).

Con esto nos referimos a que las salidas deseadas ya son valores conocidos por lo tanto los pesos son modificados con el fin de que la salida de la red (predicción) se aproxime a estos valores.

Existen dos formas de llevar a cabo este aprendizaje:

1. **Aprendizaje por corrección de error:** Consiste en ajustar los pesos en función del error, es decir, de la diferencia entre los valores de la salida deseada y las predicciones obtenidas en la salida de la red.
2. **Aprendizaje estocástico:** Consiste en realizar cambios aleatorios en los pesos de la red y evaluar su efecto a partir de la salida deseada y de distribuciones de probabilidad.

Algunos métodos y algoritmos de aprendizaje supervisado son:

- K vecinos más próximos
- Redes neuronales artificiales
- Máquinas de vectores de soporte
- Clasificador Bayesiano
- Árboles de decisión
- Regresión logística

### ■ **Aprendizaje no supervisado**

El aprendizaje no supervisado permite que el algoritmo encuentre un patrón oculto en un conjunto de datos. Con el aprendizaje no supervisado no hay una respuesta correcta o incorrecta, es solo un caso de ejecutar el algoritmo de aprendizaje automático y ver qué patrones y resultados ocurren.

El aprendizaje no supervisado podría ser más un caso de minería de datos que de aprendizaje real (Bell, 2005).

En este tipo de aprendizaje se suelen considerar dos tipos:

1. **Aprendizaje Hebbiano:** Consiste en ajustar los pesos de acuerdo a la correlación cuando las dos neuronas están activas, la conexión entre ellas se refuerza, sin embargo, cuando una está activa y la otra no, la conexión se debilita.
2. **Aprendizaje competitivo y cooperativo:** En este caso las neuronas compiten unas con otras con el fin de llevar a cabo una tarea dada. Se pretende que cuando se presente a la red cierta información de entrada, solo una de las neuronas de salida se active, por lo tanto, las neuronas compiten por activarse, quedando finalmente una como la neurona vencedora.

A diferencia del aprendizaje supervisado, en éste tipo de aprendizaje los modelos son ajustados tomando en cuenta sólo los datos de entrada sin importar los de salida, es decir los datos no están clasificados ni etiquetados.

Algunos métodos y algoritmos de aprendizaje no supervisado son:

- K-medias
  - Mezcla de gaussianas
  - Agrupamiento jerárquico
  - Mapas auto-organizados
- **Aprendizaje por refuerzo**

En el paradigma de aprendizaje por refuerzo, el aprendizaje ocurre por prueba y error, teniendo como resultado una recompensa o un castigo (recompensa negativa), y el objetivo es lograr la recompensa más alta a largo plazo. Se podría decir que el aprendizaje por refuerzo es una evolución continua u optimización a lo largo del tiempo (Arnaldo, 2018).

Este aprendizaje es el más apegado a la psicología conductista de los humanos, ya que es un modelo acción-recompensa, busca que el algoritmo se ajuste a la mejor recompensa, que está dada por el ambiente y además las acciones que puede tomar están sujetas a esas recompensas. Es por esta razón el aprendizaje por refuerzo será usado para resolver nuestro problema.

Algunos algoritmos de aprendizaje por refuerzo son:

- Programación dinámica
- Monte Carlo
- Diferencias Temporales

### 2.2.4. Aprendizaje por Refuerzo (RL)

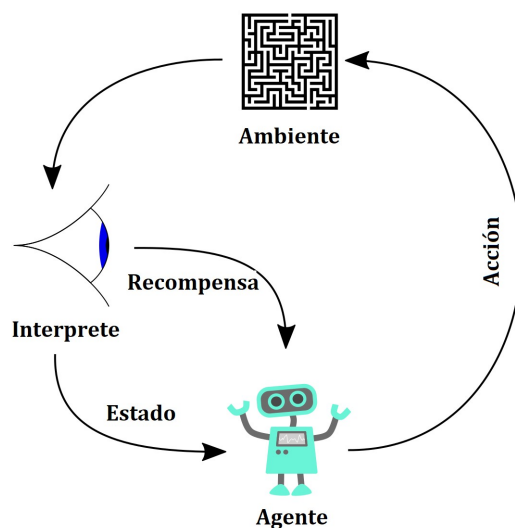
El aprendizaje por refuerzo (RL, por sus siglas en inglés “Reinforcement Learning”) es el área del aprendizaje automático que se ocupa de la toma de decisiones secuenciales.

RL tiene como objetivo permitir que un agente aprenda a comportarse en un entorno, donde la única retroalimentación es una señal de recompensa (valor numérico). El objetivo del agente es realizar acciones que maximicen la señal de recompensa a largo plazo (Wiering Marco, 2012), la distinción entre el agente y el entorno puede no ser intuitiva, todo lo que el agente no puede controlar se considera parte del entorno.

En los casos más interesantes y desafiantes, las acciones pueden afectar no solo la recompensa inmediata sino también la próxima situación y, a través de eso, todas las recompensas posteriores. Las características de búsqueda por prueba y error y la recompensa retrasada son las dos características distintivas más importantes del aprendizaje

por refuerzo.

En la Figura 2.6, se muestra el flujo que siguen los algoritmos de aprendizaje por refuerzo.



**Figura 2.6:** Flujo del Aprendizaje por Refuerzo. Imagen del usuario Megajuce de Wikipedia, traducida al idioma español (CC0 1.0), recuperada de [https://es.wikipedia.org/wiki/Archivo:Reinforcement\\_learning\\_diagram.svg](https://es.wikipedia.org/wiki/Archivo:Reinforcement_learning_diagram.svg)

### Objetivo:

En el aprendizaje por refuerzo, el propósito u objetivo del agente se establece en términos de una señal llamada recompensa que obtiene el agente del entorno. La recompensa es un número simple. El objetivo del agente es maximizar la cantidad total de recompensa que recibe. Esto significa maximizar la recompensa no inmediata, sino la recompensa acumulativa a largo plazo.

Formalizamos el problema del aprendizaje por refuerzo utilizando ideas de la teoría de sistemas dinámicos, específicamente los procesos de decisión de Markov.

Un agente de aprendizaje debe ser capaz de detectar el estado de su entorno hasta cierto punto y debe ser capaz de tomar medidas que afecten al estado. El agente también debe tener una meta o metas relacionadas con el estado del entorno.

El aprendizaje por refuerzo es diferente del aprendizaje supervisado, el tipo de aprendizaje estudiado en la mayoría de las investigaciones actuales en el campo del aprendizaje automático ya que el objetivo del aprendizaje por refuerzo es que el siste-

ma extrapole o generalice sus respuestas para que actúe correctamente en situaciones no presentes en el conjunto de entrenamiento.

Aunque uno podría estar tentado a pensar en el aprendizaje por refuerzo como un tipo de aprendizaje no supervisado porque no se basa en ejemplos de comportamiento correcto, el aprendizaje por refuerzo está tratando de maximizar una señal de recompensa en lugar de tratar de encontrar un patrón oculto.

Uno de los desafíos que surgen en el aprendizaje por refuerzo, y no en otros tipos de aprendizaje, es el intercambio entre exploración y explotación. Para obtener una gran recompensa, un agente de aprendizaje por refuerzo debe preferir las acciones que ha intentado en el pasado y que ha resultado eficaz para producir recompensas. Pero para descubrir tales acciones, tiene que probar acciones que no ha seleccionado antes. El agente tiene que explotar lo que ya ha experimentado para obtener una recompensa, pero también tiene que explorar para hacer mejores selecciones de acción en el futuro. El dilema es que ni la exploración ni la explotación pueden realizarse exclusivamente sin fallar en la tarea. El agente debe probar una variedad de acciones y favorecer progresivamente las que parecen ser las mejores.

De todas las formas de aprendizaje automático, el aprendizaje por refuerzo es el más cercano al tipo de aprendizaje que hacen los humanos y otros animales, y muchos de los algoritmos centrales del aprendizaje por refuerzo se inspiraron originalmente en los sistemas de aprendizaje biológico.

### 2.2.4.1. Elementos del aprendizaje por refuerzo

A parte del agente y del entorno, se pueden identificar cuatro subelementos principales de un sistema de aprendizaje por refuerzo (Sutton, 1998):

- Una política.
- Una señal de recompensa.
- Una función de valor.
- Un modelo del entorno (modelo del ambiente con el que interactúa).

A continuación se presenta información acerca de cada uno de estos elementos (Sutton, 1998):

El alumno o la persona que toma las decisiones se llama **agente**.

El ambiente con que interactúa, que comprende todo lo que está fuera del agente, se llama **entorno**. Estos interactúan continuamente, el agente selecciona acciones y el

entorno responde a estas acciones y presenta nuevas situaciones al agente.

Una **política** define la forma de comportarse del agente de aprendizaje en un momento dado. En términos generales, una política es un mapeo de los estados percibidos del entorno a las acciones que deben tomarse en esos estados. Corresponde a lo que en psicología se llamaría un conjunto de reglas o asociaciones de estímulo-respuesta. En algunos casos, la política puede ser una función simple o una tabla de búsqueda, mientras que en otros puede implicar un cálculo extenso, como un proceso de búsqueda. La política es el núcleo de un agente de aprendizaje de refuerzo, en el sentido de que la política es suficiente para determinar el comportamiento de este. En general, las políticas pueden ser estocásticas, especificando probabilidades para cada acción.

Una **señal de recompensa** define el objetivo de un problema de aprendizaje por refuerzo. En cada paso de tiempo, el entorno envía al agente un número llamado recompensa. El único objetivo del agente es maximizar la recompensa total que recibe a largo plazo. La señal de recompensa define así cuáles son los eventos buenos y malos para el agente. En un sistema biológico, podríamos pensar que las recompensas son análogas a las experiencias de placer o dolor. La señal de recompensa es la base principal para alterar la política, si una acción seleccionada por la política es seguida por una recompensa baja, entonces la política puede cambiarse para seleccionar otra acción en esa situación en el futuro.

Mientras que la señal de recompensa indica lo que es bueno en un sentido inmediato, una **función de valor** especifica lo que es bueno a largo plazo. En términos generales, el valor de un estado es la cantidad total de recompensa que un agente puede esperar acumular en el futuro, a partir de ese estado. Mientras que las recompensas determinan la conveniencia inmediata, los valores indican la deseabilidad a largo plazo de los estados.

Las recompensas son, en cierto sentido, primarias, mientras que los valores, como predicciones de recompensas, son secundarios. Sin recompensas no podría haber valores, y el único propósito de estimar valores es lograr más recompensa.

Las elecciones de acción se realizan en base a juicios de valor. Buscamos acciones que generen estados de mayor valor, no la mayor recompensa, porque estas acciones obtienen la mayor cantidad de recompensa para nosotros a largo plazo.

De hecho, el componente más importante de casi todos los algoritmos de aprendizaje por refuerzo que consideramos es un método para estimar valores de manera eficiente.

El cuarto y último elemento de algunos sistemas de aprendizaje por refuerzo es un **modelo del entorno**. Esto es algo que imita el comportamiento del entorno, o más generalmente, que permite hacer inferencias sobre cómo se comportará el entorno. Por ejemplo, dado un estado y una acción, el modelo podría predecir el siguiente estado

resultante y la próxima recompensa. Los modelos se utilizan para la planificación.

### 2.2.4.2. Aprendizaje basado en modelo y libre de modelo

Los métodos para resolver problemas de aprendizaje por refuerzo que usan modelos y planificación se denominan métodos basados en modelos, en oposición a los métodos más simples sin modelos que son explícitamente aprendices de prueba y error, vistos como casi lo opuesto a la planificación.

La distinción entre algoritmos de aprendizaje por refuerzo sin modelo (Free-Model) y basados en modelo (Based-Model) corresponde a la distinción que hacen los psicólogos entre el control habitual y el objetivo de los patrones de comportamiento aprendidos. Los hábitos son patrones de comportamiento desencadenados por estímulos apropiados y luego se realizan de manera más o menos automática. El comportamiento dirigido a objetivos, tiene un propósito en el sentido de que está controlado por el conocimiento del valor de los objetivos y la relación entre las acciones y sus consecuencias (Wiering Marco, 2012).

Al principio del aprendizaje, el proceso de planificación de un sistema basado en modelos es más confiable porque encadena predicciones a corto plazo que pueden ser precisas con menos experiencia que las predicciones a largo plazo del proceso sin modelos. Pero con una experiencia continua, el proceso sin modelos se vuelve más confiable porque la planificación es propensa a cometer errores debido a imprecisiones del modelo y atajos necesarios para hacer posible la planificación.

Aprendizaje por refuerzo se ocupa principalmente de cómo obtener una política óptima cuando dicho modelo no está disponible. Agrega a los procesos de decisión de Markov (MDP, por sus siglas en inglés "Markov Decision Process") un enfoque en la aproximación y la información incompleta, y la necesidad de muestreo y exploración.

Los métodos libres de modelo no se basan en la disponibilidad de modelos de transición y recompensa conocidos a priori, es decir un modelo del MDP. La falta de un modelo genera la necesidad de muestrear el MDP para reunir conocimiento estadístico sobre este modelo desconocido. En métodos libres de modelo, todavía se puede elegir entre dos opciones, aprender primero el modelo de transición y recompensa de la interacción con el entorno y después de eso, cuando el modelo es (aproximadamente o suficientemente) correcto, se aplican todos los métodos de programación dinámica (Ernst, 2009).

Un aspecto importante de los algoritmos sin modelo es que existe una necesidad de exploración. Debido a que el modelo es desconocido, el agente tiene que probar diferentes funciones para ver sus resultados. Un algoritmo de aprendizaje tiene que encontrar un equilibrio entre exploración y explotación, es decir, para obtener una gran

recompensa, el agente tiene que explotar su conocimiento actual sobre buenas acciones, aunque a veces debe probar diferentes acciones para explorar el entorno para encontrar posibles mejores acciones.

Dicho de otro modo, un agente de RL incluye uno o más de los siguientes componentes:

- Una representación de una función de valor que proporciona una predicción de cuán bueno es cada estado o cada par de estado / acción.
- Una representación directa de la política  $\pi(s)$  o  $\pi(s, a)$ .
- Un modelo del entorno (la función de transición estimada y la función de recompensa estimada) junto con un algoritmo de planificación.

Los primeros dos componentes están relacionados con lo que se llama RL libre de modelo (Free-Model). Cuando se usa el último componente, el algoritmo se denomina RL basado en modelo (Based-Model).

#### 2.2.4.3. Interacción Agente-Ambiente

El problema general de RL se formaliza como un proceso de control estocástico de tiempo discreto donde un agente interactúa con su entorno de la siguiente manera: El agente comienza, en un estado dado dentro de su entorno  $s_0 \in S$ , reuniendo un observación inicial  $\omega_0 \in \Omega$ . En cada paso de tiempo  $t$ , el agente tiene que tomar una acción  $a_t \in A$ . Esto sigue tres consecuencias (Sutton, 1998):

1. Obtiene una recompensa  $r_t \in R$
2. Obtiene las transiciones de estado a  $s_{t+1} \in S$ , y
3. Obtiene una observación  $\omega_{t+1} \in \Omega$ .

Este proceso de interacción agente-ambiente se muestra en la Figura 2.7.




Figura 2.7: Interacción Agente-Ambiente en RL.

### 2.2.5. Procesos de decisión de Markov (MDPs)

Los procesos de decisión de Markov (MDP, por sus siglas en inglés "Markov Decision Process") se pueden considerar como un tipo de problema de decisión secuencial donde se cumple la propiedad de Markov (Bellman, 1958) la cual nos dice que la probabilidad de observar un estado en el tiempo siguiente solo depende del estado presente y no de los estados observados en el pasado.

Un proceso estocástico define matemáticamente la evolución temporal de un conjunto de variables aleatorias, o dicho de otra manera un proceso estocástico caracteriza una sucesión de variables aleatorias que depende de un parámetro, generalmente el tiempo. Las cadenas de Markov son un formalismo matemático para describir variables aleatorias que cambian en el tiempo.

En un proceso estocástico de Markov el parámetro está representado por el tiempo y también este proceso cumple con la propiedad de Markov. En las cadenas de Markov tenemos estados finitos y tiempo discreto.

Los procesos de decisión de Markov son una extensión de las cadenas de Markov donde se incorporan las acciones del agente.

El agente, a través de las acciones, va a poder cambiar las probabilidades de transición de estado. Las acciones se toman de acuerdo a una política. La política es una función que le dice al agente, dado un estado, qué acción le conviene tomar.

Formalmente, un proceso de decisión de Markov  $M$  es una tupla  $M = \langle S, A, \Phi, R \rangle$  (Sutton, 1998), donde (Dutta, 2018):

- $S$ : Conjunto de estados.
- $A$ : Conjunto de acciones (pueden depender de cada estado).
- $R$ : Función de recompensa que define la meta. Mapea cada estado-acción a un número (recompensa), indicando lo deseable del estado.
- $\Phi : A \times S \rightarrow \Pi(S)$ : Función de transición de estados dada una distribución de probabilidad. Indica la probabilidad de alcanzar el estado  $s' \in S$  al realizar la acción  $a \in A$  en el estado  $s \in S$  que se puede denotar como  $\Phi(a, s, s')$ .
- Política ( $\pi$ ): Define cómo se comporta el sistema en cierto tiempo. Es un mapeo de los estados a las acciones.  
Ejemplos de políticas de selección de acciones son (Sucar):

- $\epsilon - greedy$  : Donde la mayor parte del tiempo se selecciona la acción que da el mayor valor estimado (función de valor), pero con una probabilidad  $\epsilon$  se

selecciona una acción aleatoriamente.

- *softmax* : Donde la probabilidad de selección de cada acción depende de su valor estimado (función de valor). La más común sigue una distribución de Boltzmann o de Gibbs, y selecciona una acción con la siguiente probabilidad:

$$\frac{e^{Q_t(a)/\gamma}}{\sum_{b=1}^n e^{Q_t(b)/\gamma}} \quad (2.10)$$

donde:

$Q_t(a)$  corresponde a la recompensa esperada de la acción  $a$  y  $\gamma$  es un parámetro positivo (denominado en estadística mecánica, parámetro de temperatura).

En un MDP finito, los conjuntos de estados, acciones y recompensas ( $S$ ,  $A$  y  $R$ ) tienen un número finito de elementos. En este caso, las variables aleatorias  $R_t$  y  $S_t$  tienen distribuciones de probabilidad discretas bien definidas que dependen solo del estado y la acción anteriores.

En un proceso de decisión de Markov, la probabilidad de cada valor posible para  $S_t$  y  $R_t$  depende sólo del estado y la acción inmediatamente anteriores,  $S_{t-1}$  y  $A_{t-1}$ .

El estado debe incluir información sobre todos los aspectos de la interacción entre el agente y el entorno del pasado que marquen una diferencia para el futuro. Si es así, se dice que el estado tiene la propiedad Markov. Esta información puede estar determinada por ejemplo por lecturas directas de sensores o descripciones simbólicas de objetos en una habitación.

Las acciones pueden ser cualquier decisión que queramos aprender a tomar, y los estados pueden ser cualquier cosa que podamos saber que pueda ser útil para tomarlas.

### 2.2.5.1. Políticas y funciones de valor

Casi todos los algoritmos de aprendizaje por refuerzo implican estimar funciones de valor: funciones de estados (o de pares de estado-acción) que estiman qué tan bueno es para el agente estar en un estado dado (o qué tan bueno es realizar una acción dada en un determinado estado). La noción de cuán bueno, aquí se define en términos de recompensas futuras que se pueden esperar o, para ser precisos, en términos de rendimiento esperado. Por supuesto, las recompensas que el agente puede esperar recibir en el futuro dependen de las acciones que tomará (Wiering Marco, 2018).

En consecuencia, las funciones de valor se definen con respecto a formas particulares de actuar, llamadas políticas.

Una política es un mapeo de estados a probabilidades de seleccionar cada acción posible, define como un agente selecciona las acciones. Las políticas pueden clasificarse bajo el criterio de ser estacionarias o no estacionarias.

Una política no estacionaria depende del paso de tiempo y es útil para el contexto de horizonte finito donde las recompensas acumulativas que el agente busca optimizar se limitan a un número finito de pasos de tiempo futuros. Las políticas también se pueden clasificar bajo un segundo criterio de ser determinista o estocástico:

- En el caso determinista, la política se describe mediante  $\pi(s) : S \rightarrow A$ .
- En el caso estocástico, la política se describe mediante  $\pi(s, a) : S \times A \rightarrow [0, 1]$  donde  $\pi(s, a)$  denota la probabilidad de que la acción  $a$  se pueda elegir en el estado  $s$ .

Si el agente sigue la política  $\pi$  en el tiempo  $t$ , entonces  $\pi(a|s)$  es la probabilidad de que  $A_t = a$  si  $S_t = s$ . Como  $\pi$  es una función ordinaria, el "|" en medio de  $(a|s)$  simplemente recuerda que se define una distribución de probabilidad sobre  $a \in A(s)$  para cada  $s \in S$ .

Los métodos de aprendizaje por refuerzo especifican cómo se cambia la política del agente como resultado de su experiencia.

La función de valor de un estado  $s$  bajo una política  $\pi$ , denotada  $v_\pi(s)$ , es el rendimiento esperado cuando se inicia en  $s$  y a partir de eso se sigue  $\pi$ . Para los MDP, se define  $v_\pi$  formalmente por (Sutton, 1998):

$$v_\pi(s) \doteq \mathbb{E}[G_t | S_t = s] = \mathbb{E}_\pi \left[ \sum_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = t \right] \text{ para todo } s \in S \quad (2.11)$$

donde  $\mathbb{E}_\pi[\cdot]$  denota el valor esperado de una variable aleatoria dado que el agente sigue la política  $\pi$  y  $t$  es cualquier paso de tiempo. Teniendo en cuenta que el valor del estado terminal, si lo hay, es siempre cero. Llamamos a la función  $v_\pi$  la función estado-valor para la política  $\pi$ .

De manera similar, definimos el valor de tomar la acción  $a$  en el estado  $s$  bajo una política  $\pi$ , denotada por  $q_\pi(s, a)$ , como el rendimiento esperado a partir de  $s$ , tomando la acción  $a$  siguiendo la política  $\pi$ :

$$q_\pi(s, a) \doteq \mathbb{E}[G_t | S_t = s, A_t = a] = \mathbb{E}_\pi \left[ \sum_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = t, A_t = a \right] \quad (2.12)$$

### 2.2.5.2. Políticas óptimas y funciones de valor óptimas

Resolver una tarea de aprendizaje por refuerzo significa encontrar una política que logre muchas recompensas a largo plazo. Una política  $\pi$  se define para ser mejor o

igual a una política  $\pi'$  si su rendimiento esperado es mayor o igual que el de  $\pi'$  para todos los estados. En otras palabras,  $\pi \geq \pi'$  si y sólo si  $v_\pi(s) \geq v_{\pi'}(s)$  para todos los  $s \in S$ .

Siempre hay al menos una política que es mejor o igual a todas las demás, a esta la llamamos política óptima. Aunque puede haber más de una, denotamos todas las políticas óptimas por  $\pi_*$ . Comparten la misma función de valor de estado, llamada función óptima estado-valor, denotada  $v_*$  y definida en (Sutton, 1998) como

$$v_*(s) = \max_{\pi} v_{\pi}(s), \text{ para todo } s \in S \quad (2.13)$$

Las políticas óptimas también comparten la misma función óptima acción-valor, denotada  $q_*$ , y definida como

$$q_*(s, a) = \max_{\pi} q_{\pi}(s, a), \text{ para todo } s \in S \text{ y } a \in A \quad (2.14)$$

Para el par de estado-acción  $(s, a)$ , esta función proporciona el rendimiento esperado para tomar la acción  $a$  en el estado  $s$  y luego seguir una política óptima. Por lo tanto, se puede escribir  $q_*$  en términos de  $v_*$  de la siguiente manera:

$$q_*(s, a) = \mathbb{E}[R_{t+1} + \gamma v_*(S_{t+1}) | S_t = s, A_t = a] \quad (2.15)$$

### 2.2.6. Métodos de solución de aprendizaje por refuerzo

Algunos ejemplos de métodos de solución son:

#### 2.2.6.1. Programación Dinámica

Programación dinámica (DP, por sus siglas en inglés "Dynamic programming") se refiere a una clase de algoritmos capaz de calcular políticas óptimas en presencia de un modelo perfecto del entorno. La suposición de que un modelo está disponible será difícil de garantizar para muchas aplicaciones. Sin embargo desde un punto de vista teórico, así como desde un punto de vista algorítmico, los algoritmos DP son muy relevantes porque definen mecanismos computacionales fundamentales que también se usan cuando no hay un modelo disponible (Wiering Marco, 2012).

La programación dinámica consiste en la iteración de políticas. Se calcula primero la función de valor dada una política que elige la mejor de las acciones de acuerdo al método e-greedy.

La idea clave de DP, y del aprendizaje por refuerzo en general, es el uso de funciones de valor para organizar y estructurar la búsqueda de buenas políticas. Podemos obtener fácilmente políticas óptimas una vez que hayamos encontrado las funciones de valor óptimas,  $v_*$  o  $q_*$ , que satisfacen las ecuaciones de optimización de Bellman (Sutton,

1998):

$$\begin{aligned} v_*(s) &= \max_a \mathbb{E} [R_{t+1} + \gamma v_*(S_{t+1}) | S_t = s, A_t = a] \\ &= \max_a \sum_{s', r} p(s', r | s, a) [r + \gamma v_*(s')], \text{ o} \end{aligned} \quad (2.16)$$

$$\begin{aligned} q_*(s, a) &= \mathbb{E} [R_{t+1} + \gamma \max_{a'} q_*(S_{t+1}, a') | S_t = s, A_t = a] \\ &= \sum_{s', r} p(s', r | s, a) [r + \gamma \max_{a'} q_*(s', a')] \end{aligned} \quad (2.17)$$

para todo  $s \in S$ ,  $a \in A$  y  $s' \in S^+$ .

Los algoritmos DP se obtienen convirtiendo las ecuaciones de Bellman (Sutton, 1998) como estas en asignaciones, es decir, en reglas de actualización para mejorar las aproximaciones de las funciones de valor deseadas.

### 2.2.6.2. Métodos de Monte Carlo

Las técnicas de Monte Carlo mantienen los conteos de frecuencia en pares de estado-acción y futuras recompensas-sumas (retornos) y basan sus valores en estas estimaciones. Estos métodos sólo requieren muestras para estimar el rendimiento promedio de las muestras, además no asumimos un conocimiento completo del ambiente. Por ejemplo, en la evaluación de políticas de Monte Carlo, para cada estado  $s$  todos los rendimientos obtenidos de  $s$  se mantienen y el valor de un estado  $s$  es solo su promedio. Estos algoritmos tratan la recompensa a largo plazo como una variable aleatoria y toman como estimación la media muestreada (Wiering Marco, 2012).

Para estimar  $V$  (Función Valor) y  $Q$  (Función estado-acción) podemos tomar estadísticas haciendo un promedio de las recompensas obtenidas.

### 2.2.6.3. Diferencias Temporales

El aprendizaje de diferencias temporales (TD, por sus siglas en inglés "Temporal Difference") es una combinación de ideas de Monte Carlo y de programación dinámica. Como en los métodos de Monte Carlo, los métodos de TD pueden aprender directamente de la experiencia sin un modelo del entorno. Así como al igual que programación dinámica, los métodos TD actualizan las estimaciones basadas en parte en otras estimaciones aprendidas, sin esperar un resultado final (Sutton, 1998).

Métodos de diferencias temporales sólo tienen que esperar el siguiente paso, usan el error o diferencia entre predicciones sucesivas en lugar del error entre la predicción y la salida final.

De acuerdo con (Sutton, 1998) los métodos TD y Monte Carlo utilizan la experiencia para resolver el problema de predicción. Dada cierta experiencia siguiendo una política

$\pi$ , ambos métodos actualizan su estimación  $V$  de  $v_\pi$  para los estados no terminales  $S_t$  que ocurren en esa experiencia. En términos generales, los métodos de Monte Carlo esperan hasta que se conozca el retorno después de la visita, luego usan ese retorno como un objetivo para  $V(S_t)$ . Un método simple de Monte Carlo para cada visita adecuado para entornos no estacionarios es

$$V(S_t) \leftarrow V(S_t) + \alpha[G_t - V(S_t)] \quad (2.18)$$

donde  $G_t$  es el retorno real después del tiempo  $t$ , y  $\alpha$  es un parámetro de tamaño de paso constante. Mientras que los métodos de Monte Carlo deben esperar hasta el final del episodio para determinar el incremento a  $V(S_t)$  (solo entonces se conoce  $G_t$ ), los métodos de TD deben esperar sólo hasta el siguiente paso. En el momento  $t+1$  forman inmediatamente un objetivo y realizan una actualización útil utilizando la recompensa observada  $R_{t+1}$  y la estimación  $V(S_{t+1})$ . El método TD más simple hace la actualización inmediatamente en la transición a  $S_{t+1}$  y recibiendo  $R_{t+1}$ .

$$V(S_t) \leftarrow V(S_t) + \alpha[R_{t+1} + \gamma V(S_{t+1}) - V(S_t)] \quad (2.19)$$

Por lo tanto, el objetivo para la actualización de Monte Carlo es  $G_t$ , mientras que el objetivo para la actualización de TD es  $R_{t+1} + \gamma V(S_{t+1})$ . Este método TD se llama TD (0).



---

## Capítulo 3

# Diseño del experimento

---

En el presente capítulo se presentan de manera general los dos modelos de redes neuronales artificiales que fueron empleados como base para este trabajo. Después se tiene la información acerca de la obtención de datos para cada una de las redes neuronales, donde se plantean cada uno de los escenarios para los dos problemas tratados y con ellos se procede a la identificación de cada uno de los elementos de aprendizaje por refuerzo.

Finalmente, se añade la validación de los modelos propuestos.

### **3.1. Modelos propuestos de aprendizaje por refuerzo para redes neuronales**

En la actualidad existen diversos avances acerca de simulaciones del cerebro, ejemplo de estos avances es el proyecto Blue Brain, el cual tiene como objetivo estudiar la estructura del cerebro creando una simulación de todo el cerebro a nivel molecular. Esta ingeniería inversa del comportamiento permitirá avanzar en el entendimiento del funcionamiento del cerebro así como estudiar sus disfunciones (EPFL).

La simulación de su comportamiento basada en un supercomputador convierte la comprensión del cerebro en un problema manejable, proporcionando una nueva herramienta para estudiar las complejas interacciones dentro de los diferentes niveles de organización del cerebro e investigar los enlaces de niveles cruzados que conducen de los genes a la cognición (EPFL).

Sin embargo, durante una exhaustiva búsqueda de trabajos de investigación similares al que se plantea en esta tesis, nos encontramos que el trabajo realizado por Marat Rvachev en 2013 (M. Rvachev, 2013) nos servía como base principal, ya que en su trabajo él propone el modelo llamado RMCS y realiza la validación del mismo planteando un mecanismo similar al de un músculo, el problema planteado se denomina “Manza-

### 3. DISEÑO DEL EXPERIMENTO

---

nas y piedras”, donde el objetivo es que un individuo aprenda a reconocer entre una manzana y una roca para comérsela o lanzarla.

Como parte de su validación el autor realiza comparaciones de manera parcial con otros modelos como el BP (por sus siglas en inglés ”Back-Propagation”), con la diferencia que usa aprendizaje por refuerzo para el algoritmo de aprendizaje de esta red, es decir, se usa el algoritmo de diferencias temporales el cual está basado principalmente en el aprendizaje por refuerzo y en el retraso de la recompensa.

Al tratarse de un problema de toma de decisiones con lo que el autor valida su modelo, es que se decide hacer uso de estos dos para ser implementados en los problemas que nos planteamos en esta tesis.

En cada uno de estos modelos se implementará un componente de memoria combinatoria que llamamos componente  $C_j$ , en el cual registramos la cantidad de conexiones excitatorias e inhibitorias para poder calcular los pesos sinápticos de las neuronas de la capa oculta en cada una de las redes neuronales propuestas. En el caso del modelo RMCS (M. Rvachev, 2013) este componente de memoria combinatoria nos servirá para conocer la cantidad de conexiones excitatorias e inhibitorias que fueron necesarias para desempeñar las acciones que implican obtener la mayor recompensa, es decir, los mejores resultados en el aprendizaje. Para el caso del modelo BP con diferencias temporales este componente de memoria nos servirá para saber qué cantidad de las distintas conexiones fueron necesarias en los casos en que se consiga una mejor predicción de los resultados, ya que en este modelo primero calculamos el valor de la salida deseada de acuerdo a una recompensa.

Cabe mencionar que durante el resto del capítulo usaremos términos inusuales para nombrar los elementos de una red neuronal, esto con el fin de respetar la terminología propuesta por (M. Rvachev, 2013).

En los dos modelos propuestos usaremos una red neuronal multicapa, una capa de entrada llamada capa  $L_1$ , una capa de salida llamada capa  $L_2$  y tendremos grupos sinápticos por cada una neurona de las neuronas en la capa de salida, esto se refiere a las neuronas en la capa oculta (llamadas vecindarios de sinapsis  $N_j$ ), estas neuronas tienen conexiones sinápticas de máximo 4 conexiones con las neuronas de la capa de entrada.

Esta red a nivel biológico representa las conexiones generadas entre las neuronas sensoriales ubicadas en el mesencéfalo (cerebro) que envían información a las neuronas conductoras o motoneuronas ubicadas en la médula espinal y estas a su vez envían la información a los músculos que son los encargados de responder realizando la acción.

Después de haber aclarado la terminología usada se presentan los detalles para cada

una de las redes neuronales, usando los dos diferentes modelos de aprendizaje que se proponen, incluyendo el componente Cj dada su relevancia.

### 3.1.1. Componente de memoria combinatoria Cj

El componente Cj está representado por la siguiente expresión, donde  $w_{ij}$  se refiere a los pesos sinápticos y  $X$  al conjunto de vectores de entrada de la red identificados cada uno por  $X_i$ .

$$C_j(X) = \gamma_j H(n_j - n_j^* - \bar{n}_j) \quad (3.1)$$

Donde:

- Conexiones Sinápticas Excitatorias Activas de  $N_j$

$$n_j : n_j = \sum_{w_{ij} > 0} w_{ij} X_i \quad (3.2)$$

- Conexiones Sinápticas Excitatorias de  $N_j$

$$n_j^* : n_j^* = \sum_{w_{ij} > 0} w_{ij} > 0 \quad (3.3)$$

- Conexiones Sinápticas Inhibitorias Activas de  $N_j$

$$\bar{n}_j : \bar{n}_j = - \sum_{w_{ij} < 0} w_{ij} X_i \geq 0 \quad (3.4)$$

- Función  $H(n)$

$$H(n) : H(n) = \begin{cases} 1, & n \geq 0 \\ 0, & n < 0 \end{cases} \quad (3.5)$$

- Pesos de Vecindario  $N_j$

$$\gamma_j : \gamma_j = \begin{cases} 1, & \text{si } N_j \text{ está excitado, es decir } H(n) = 1, \\ 0, & \text{si } N_j \text{ no está excitado, es decir } H(n) = 0. \end{cases} \quad (3.6)$$

En el Apéndice A, sección A.7 se encuentra un análisis de este componente de memoria combinatoria Cj.

#### 3.1.2. Modelo RMCS

Para la red neuronal de este modelo, el total de neuronas en la capa de entrada  $L_1$  será de  $n$  neuronas sensoriales, por lo que estarán representadas por el total de características del objeto u obstáculo presentado durante la etapa de aprendizaje de la red neuronal, el estado de estas neuronas es 1 cuando se encuentra activa, es decir, cuando la característica está presente y 0 cuando se encuentra inactiva, o sea cuando la característica no está presente en el objeto u obstáculo presentado. Algunos ejemplos de estas características son la textura, el lugar en que se encuentra o la dimensión del objeto u obstáculo.

La capa de salida  $L_2$  consta de  $k$  neuronas motoras, representando las acciones posibles que se pueden elegir durante el aprendizaje de la red. Algunos ejemplos de esto para el caso de los objetos sería tomar el objeto de manera normal, tirarlo al piso o simplemente no hacer nada, en el caso de los obstáculos puede evitar cualquier obstáculo sin ninguna dificultad, caer al piso o tener alguna dificultad como sufrir mioclonías.

Por último en la capa oculta, los clusters sinápticos o vecindarios de sinapsis  $N_j$  dependen de las neuronas de salida, es decir, por cada neurona de salida  $k$  se tendrán  $m$  vecindarios de sinapsis, por lo tanto el total de vecindarios de sinapsis en la capa oculta será de  $(k * m)$ . Por ejemplo, si se tienen 4 neuronas en la capa de salida, por cada una de estas se asignan 10,000 vecindarios de sinapsis en la capa oculta, entonces el total de clusters sinápticos será de 40,000 en la capa oculta.

En el modelo RMCS (M. Rvachev, 2013), el método general de entrenamiento se resume a:

1. Selecciona un vector de entrada desde el conjunto de entrenamiento.
2. Aplica esta entrada a la red y calcula el componente  $C_j$  para poder calcular el peso de los vecindarios de sinapsis (neuronas de la capa oculta).
3. Obtener la salida de la red.
4. Actualizar los pesos de los vecindarios de sinapsis de acuerdo a la recompensa obtenida en la salida de la red.
5. Para cada vector de entrada del conjunto de prueba, aplica esta entrada a la red y obtén la salida de la red.
6. Registrar si la respuesta fue correcta o incorrecta de acuerdo al objeto u obstáculo de prueba presentado y a la acción obtenida en la salida de la red.
7. Repetir los pasos 1 al 6 para todas las entradas del conjunto de entrenamiento.

En la figura 3.1, se presenta el diagrama de flujo del modelo RMCS (M. Rvachev, 2013).

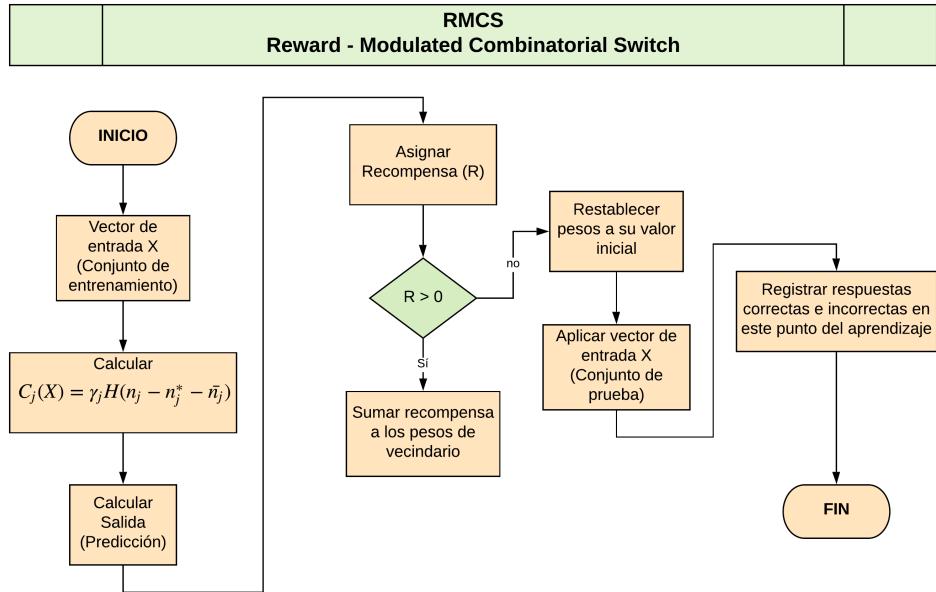


Figura 3.1: Diagrama de Flujo del Modelo RMCS

3.1.2.1. Componentes de la red neuronal

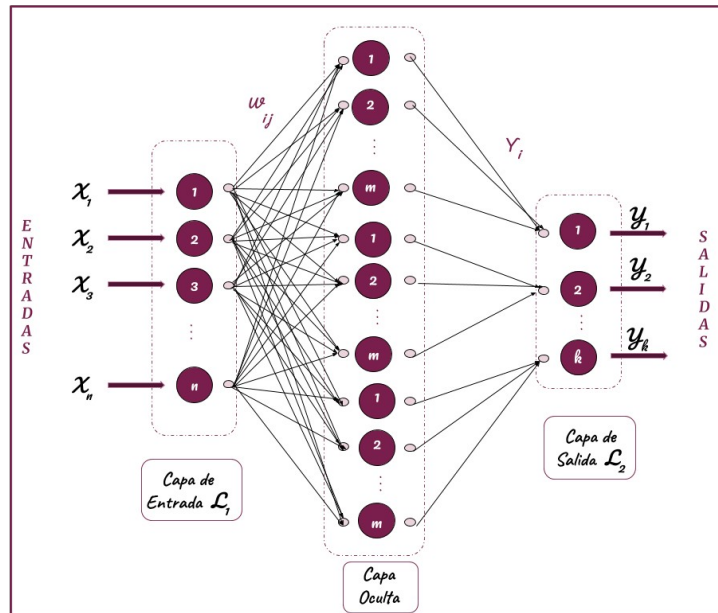


Figura 3.2: Red Neuronal Artificial para Algoritmo RMCS

### 3. DISEÑO DEL EXPERIMENTO

---

- **Entradas**

$$X_i : X_i \in \{0, 1\}, i = 1, 2, \dots, n \quad (3.7)$$

donde 0=Inactiva y 1=Activa.

- **Salidas**

$$Y_i, i = 1, 2, 3, \dots, k \quad (3.8)$$

- **Vecindarios de sinapsis**

$$N_j, j = 1, 2, \dots, (k * m) \quad (3.9)$$

- **Pesos sinápticos**

$$w_{ij} : w_{ij} \in \{-1, 0, 1\}, i = 1, 2, \dots, n, j = 1, 2, \dots, (k * m) \quad (3.10)$$

donde -1 representa que se tiene una sinapsis inhibitoria, 0 indica que no se tiene contacto de sinapsis y 1 si se trata de una sinapsis excitatoria.

- **Pesos de vecindario sináptico  $N_j$**

$$\gamma_j : \gamma_j \in \{0, 1\}, j = 1, 2, \dots, (k * m) \quad (3.11)$$

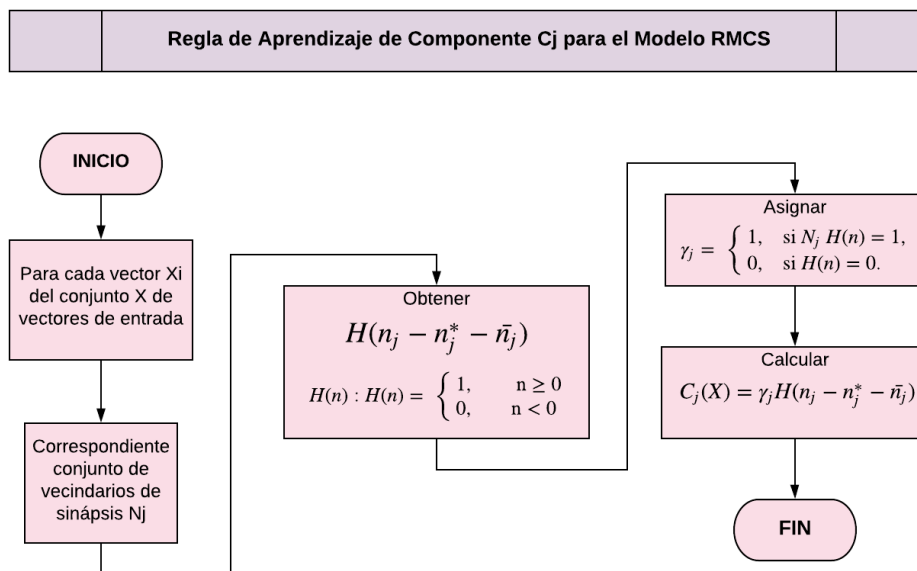
donde 0 indica que el vecindario de sinapsis no se encuentra excitado, mientras que 1 indica que se encuentra excitado, lo que determina si se produce o no la descarga del potencial de acción por el axón de esa neurona .

#### 3.1.2.2. Regla de aprendizaje del componente Cj

El aprendizaje consiste en:

Por cada vector  $X_i$  del conjunto  $X$  de vectores de entrada, calcular el componente Cj asignando los valores  $\gamma_j$  correspondientes, es decir, de acuerdo al  $X_i$  de entrada y las conexiones sinápticas en  $N_j$  calcular los pesos de estos vecindarios de sinapsis  $N_j$ .

En la figura 3.3, se presenta el diagrama de flujo que explica claramente la regla de aprendizaje de Cj para el modelo RMCS (M. Rvachev, 2013).



**Figura 3.3:** Diagrama de flujo del aprendizaje del componente Cj para el modelo RMCS

### 3.1.2.3. Algoritmo RMCS (Reward - Modulated Combinatorial Switch)

Como ya se mencionó al inicio, las entradas estarán asociadas a las características del objeto u obstáculo que se presentan al agente sobre el cual debe tomar una decisión, por lo tanto, las salidas representan cada una de las acciones que el agente puede elegir, al elegir una acción se obtiene una recompensa ya sea positiva o negativa que fortalece o debilita las conexiones neuronales que se tienen en ese momento. Por fortalecer, nos referimos a que un vecindario de sinapsis que inicia con un peso sináptico de 0 es decir envía una señal inhibitoria y al obtener recompensas positivas se fortalece, teniendo ahora un peso sináptico mayor a 0, lo cual hace que ese vecindario de sinapsis envíe una señal excitatoria. Para el caso de debilitar nos referimos a que un vecindario que inicia con un peso sináptico mayor a 0, al recibir recompensas negativas ahora tendrá un peso de 0 es decir enviará una señal inhibitoria ya que no está aportando ninguna información necesaria para realizar la acciones que den las recompensas mayores.

Para dejar esto más claro, se presenta un ejemplo:

- Supongamos que al paciente se le presenta una moneda sobre la mesa, es decir, el paciente debe tomar la moneda, las neuronas sensoriales (neuronas de entrada) envían la información de que lo que se está observando es un objeto pequeño, redondo y que está sobre la mesa, con esta información se realizan las conexiones neuronales necesarias para procesar y enviar esa información a las neuronas de la capa oculta (vecindarios de sinapsis), donde la información recibida es procesada

### 3. DISEÑO DEL EXPERIMENTO

---

por medio de los cálculos correspondientes del componente  $C_j$ , obteniendo así los pesos sinápticos de los vecindarios de sinapsis, al terminar los cálculos esta información es enviada a las neuronas motoras (neuronas de salida), donde se toma la decisión de tomar la moneda sin presentar ningún problema, tomar la moneda sufriendo mioclonías leves al momento de querer tomarla, tirar la moneda debido a las mioclonías severas o simplemente no hacer nada.

De acuerdo a la acción elegida, se obtiene una recompensa positiva o negativa que fortalece o debilita las conexiones neuronales que se tienen hasta el momento, por ejemplo, si se elige tomar la moneda sin presentar mayor dificultad, se obtendrá una recompensa positiva ya que se está realizando una acción correcta, al elegir la acción de tirar la moneda o simplemente no hacer nada se obtiene una recompensa negativa por que se trata de acciones incorrectas.

Al obtener la recompensa, este valor se acumulará o no al valor de los pesos de vecindario de sinapsis  $N_j$  que estén excitados en ese momento, esto hará que las conexiones neuronales se fortalezcan o debiliten, de acuerdo a las recompensas obtenidas, haciendo que la red aprenda. Por ejemplo, al elegir la acción de tomar la moneda sin presentar mayor dificultad obtiene una recompensa de 1, esa recompensa se acumula a los pesos sinápticos de los vecindarios de sinapsis que estén implicados, de modo que los que se encontraban con un peso de 0 pasan a tener un peso de 1, lo que significa que se fortaleció la conexión, para el caso en que la acción seleccionada sea tirar la moneda o simplemente no hacer nada, se obtiene una recompensa de -1, lo que hace que los vecindarios de sinapsis que tenían un peso sináptico de 1 pasen a tener ahora un peso sináptico de 0, lo que significa que se debilitó la conexión.

En general el aprendizaje de este modelo consiste en actualizar los pesos de los vecindarios de sinapsis  $N_j$ . Esta actualización se realiza conforme a la regla de aprendizaje del componente  $C_j$  y conforme a la recompensa obtenida por la acción elegida en la salida.

Al final de la etapa de aprendizaje, en el componente  $C_j$  se tienen los registros del total de sinapsis excitatorias e inhibitorias que fueron necesarias en la conexión sináptica que lograron desempeñar las acciones que implican obtener la mayor recompensa.

El pseudocódigo del algoritmo de la red neuronal con el modelo RMCS (M. Rvachev, 2013) se presenta en el Apéndice A, Sección A.1.

#### 3.1.3. Modelo BP con Diferencias Temporales

Para la red neuronal de este modelo, agregamos nuevos términos como lo son, la función de propagación  $h$  y la función de activación  $F$ , que para nuestro caso usamos una función sigmoidea.

El total de neuronas en la capa de entrada  $L_1$  será de  $n$  neuronas sensoriales, por lo que estarán representadas por el total de características del objeto u obstáculo presentado durante la etapa de aprendizaje de la red neuronal, el estado de estas neuronas es 1 cuando se encuentra activa, es decir cuando la característica está presente y 0 cuando se encuentra inactiva, o sea cuando la característica no está presente en el objeto u obstáculo presentado de igual modo que en el modelo RMCS (M. Rvachev, 2013).

Para el caso de la capa de salida  $L_2$ , el total de neuronas cambia; ya que aquí tendremos solamente una neurona, el por qué de esto, es debido a que los modelos Back-Propagation son usados para la clasificación, es decir, de acuerdo a las características dadas en la capa  $L_1$  se etiquetan las clases a las que corresponde el objeto u obstáculo presentado y para esto no es necesario tener más de una neurona de salida. Con esta neurona obtendremos una predicción de la clase a la que pertenece el objeto u obstáculo que sea presentado y así poder calcular el error entre la predicción y la salida deseada.

Como ya se mencionó para nuestro caso, se usa el algoritmo de diferencias temporales que es exclusivo de aprendizaje por refuerzo, que es en el que se basa este trabajo, por lo tanto, usando el algoritmo de diferencias temporales obtendremos la salida deseada de la red para cada uno de los objetos presentados (en aprendizaje supervisado esto sería la clase). En el cálculo de la salida deseada va implícita la recompensa.

Por último en la capa oculta, el total de clusters sinápticos  $N_j$  será asignado del mismo modo que en el modelo RMCS (M. Rvachev, 2013).

En BP con diferencias temporales, el método general de entrenamiento se resume a cuatro pasos:

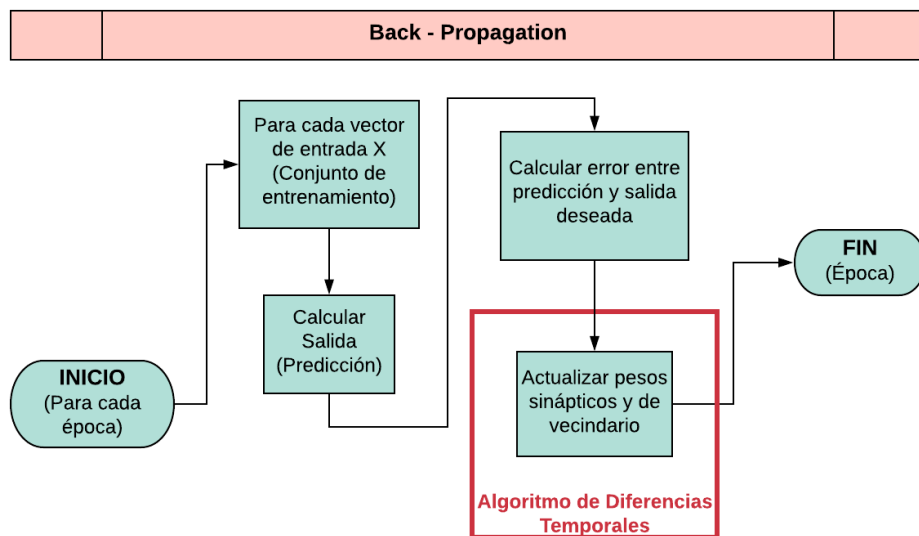
**Pasos hacia delante:**

1. Selecciona un vector de entrada desde el conjunto de entrenamiento.
2. Aplica esta entrada a la red y calcula la salida.

**Pasos hacia atrás:**

3. Calcular el error entre la salida calculada (llamada predicción) y la salida deseada de la entrada usada.
4. Ajustar los pesos sinápticos y de vecindario de sinapsis  $N_j$  con el algoritmo de diferencias temporales para que el error cometido entre la predicción y la salida deseada sea disminuido.
5. Repetir los pasos 1 al 5 para todas las entradas del conjunto de entrenamiento, hasta que el error global sea aceptablemente bajo.

En la figura 3.4 se presenta el diagrama de flujo del modelo BP con diferencias temporales.



**Figura 3.4:** Diagrama de Flujo del Modelo BP con Diferencias Temporales

### 3.1.3.1. Diferencias temporales para redes neuronales artificiales

En aprendizaje por refuerzo, resulta difícil predecir cuál es el valor esperado, por lo tanto, se necesita un algoritmo para predecir este valor. El algoritmo de aprendizaje de diferencia temporal es uno de ellos y se puede combinar con redes neuronales artificiales para aprender. Este algoritmo es el que usaremos para este trabajo.

Para comprender mejor esto, se presenta a continuación el algoritmo general de diferencias temporales para la actualización de pesos en una red neuronal multicapa.

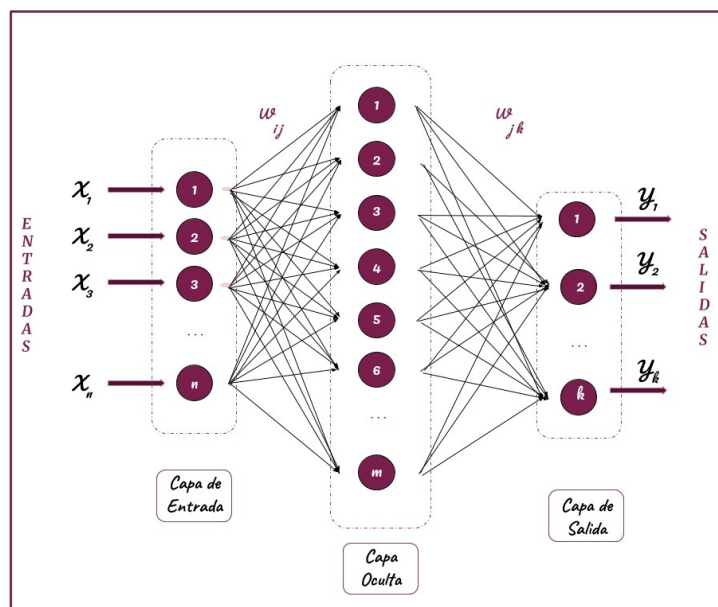
#### Algoritmo general de diferencias temporales para la actualización de pesos

La terminología usada en este algoritmo se describe a continuación:

- $X_i$  : Entrada  $i$
- $Y_k(t)$  : Salida del nodo  $k$ -ésimo en el estado  $t$ .
- $Y_k(t + 1)$  : Salida del nodo  $k$ -ésimo en el estado  $t+1$ .

- $w_{ij}$  : Peso del arco que va del nodo  $i$  al nodo  $j$
- $w_{jk}$  : Peso del arco que va del nodo  $j$  al nodo  $k$
- $D(t + 1)$  es el valor deseado del siguiente estado
- $\alpha$  es la tasa de aprendizaje (factor entre cero y uno)
- $\mu$  es el factor en descomposición (factor entre cero y uno)
- $\lambda$  factor entre cero y uno que indica cuánta retroalimentación obtiene el estado  $t$  deseado de estados futuros
- $R(t)$  es la recompensa directa en el estado  $t$
- $F'(x)$  es la derivada de la función sigmoidea  $F(x)$ , donde  $F'(x) = F(x) * (1 - F(x))$

En la figura 3.5, se muestra la red neuronal multicapa, donde se señalan cada uno de sus componentes, esto para mayor comprensión y entendimiento sobre la implementación del algoritmo de diferencias temporales para la actualización de pesos.



**Figura 3.5:** Red Neuronal Artificial para Algoritmo de Diferencias Temporales

### 3. DISEÑO DEL EXPERIMENTO

---

**Paso 1:** Calcular la función de propagación para cada una de las neuronas de la capa oculta.

$$h_j : h_j = \sum X_i w_{ij} \quad (3.12)$$

**Paso 2:** Calcular la función de activación (función sigmoidea) para cada una de las neuronas de la capa oculta.

$$F_j : F_j = \frac{1}{1 + e^{-h_j}} \quad (3.13)$$

**Paso 3:** Calcular la salida de la red (llamada predicción)

$$Y_k : Y_k = \sum w_{jk} F_j \quad (3.14)$$

**Paso 4:** Calcular el error para cada tiempo  $t$  (diferencia entre la salida deseada y la predicción)

$$E_k(t) = D_k(t) - Y_k(t) \quad (3.15)$$

donde  $D(t)$  es la salida deseada en el tiempo  $t$  y se calcula de la siguiente manera:

$$D_k(t) = \lambda * D_k(t+1) + \alpha * ((1 - \lambda) * R(t) + \mu * Y_k(t+1) - Y_k(t)) \quad (3.16)$$

Para el caso en que los datos son tomados de una secuencia de observaciones.

**Paso 5:** Calcular el Error Total

$$E_{total} = \frac{1}{2} \sum (E_k(t)^2) \quad (3.17)$$

**Paso 6:** Actualizar pesos

La regla de actualización para los pesos entre la capa de entrada y la capa oculta es:

$$w_{ij} = w_{ij} + \alpha (E_k(t) * w_{jk} * F'(h_j)) * X_i \quad (3.18)$$

La regla de actualización para los pesos entre la capa oculta y la capa de salida es:

$$w_{jk} = w_{jk} + \alpha * E_k(t) * F(h_j) \quad (3.19)$$

3.1.3.2. Componentes de la red neuronal

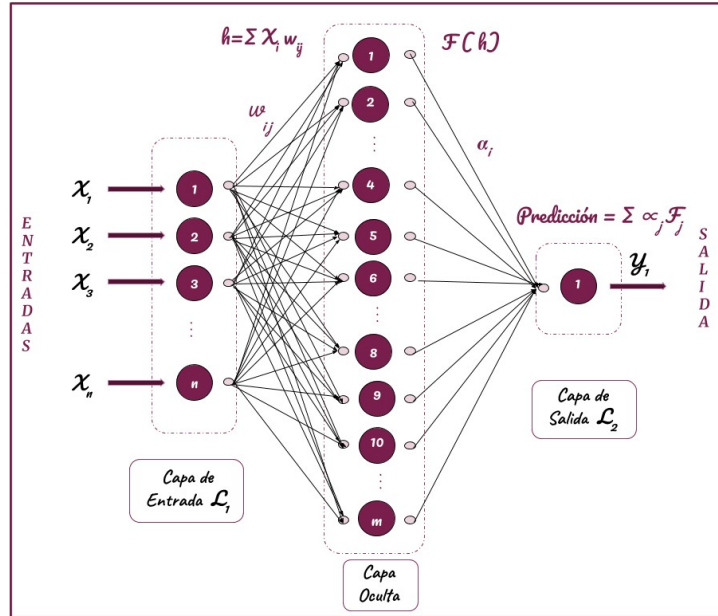


Figura 3.6: Red Neuronal Artificial para Algoritmo Back-Propagation

■ Entradas

$$X_i : X_i \in \{0, 1\}, i = 1, 2, \dots, n \quad (3.20)$$

donde 0=Inactiva y 1=Activa.

■ Vecindarios de sinapsis

$$N_j, j = 1, 2, \dots, m \quad (3.21)$$

■ Pesos sinápticos

$$w_{ij} : w_{ij} \in \{-1, 0, 1\}, i = 1, 2, \dots, n, j = 1, 2, \dots, m \quad (3.22)$$

donde -1 representa que se tiene una sinapsis inhibitoria, 0 indica que no se tiene contacto de sinapsis y 1 si se trata de una sinapsis excitatoria.

■ Función de Propagación

$$h_j = \sum X_i w_{ij} \quad (3.23)$$

para cada vecindario de sinapsis  $N_j$

■ Función de Activación

$$F_j = \frac{1}{1 + e^{-h_j}}, j = 1, 2, \dots, m, F_j \in [0, 1] \quad (3.24)$$

### 3. DISEÑO DEL EXPERIMENTO

- **Pesos de vecindario sináptico**  $N_j$

$$\alpha_j \in \{0, 1\}, j = 1, 2, \dots, m \quad (3.25)$$

donde 0 indica que el vecindario de sinapsis no se encuentra excitado, mientras que 1 indica que se encuentra excitado, lo que determina si se produce o no la descarga del potencial de acción por el axón de esa neurona.

- **Salida**

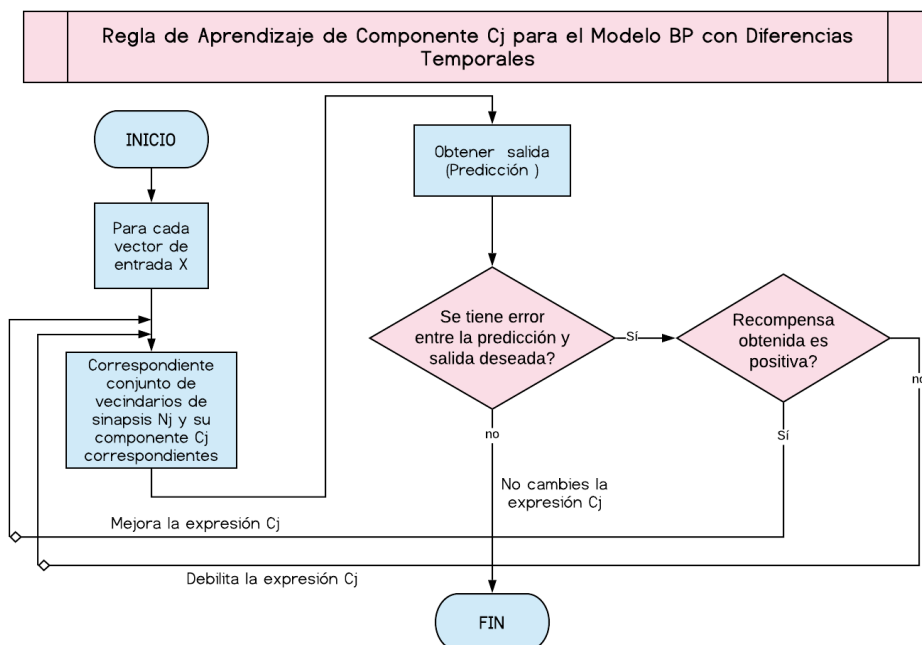
$$Y : Y = \sum \alpha_j F_j \quad (3.26)$$

#### 3.1.3.3. Regla de aprendizaje del componente $C_j$

La regla de aprendizaje para el componente de  $C_j$  en el modelo BP con diferencias temporales consiste en:

Por cada vector de entrada  $X$ , encontrar la mejor expresión  $C_j$ , es decir, la expresión que ayude a que el error entre la salida deseada y la predicción de la red sea 0.

En la Figura 3.7, se muestra el diagrama de flujo del aprendizaje del componente  $C_j$  para el modelo BP con diferencias temporales.



**Figura 3.7:** Diagrama de flujo del aprendizaje de  $C_j$  en el modelo BP con diferencias temporales

### 3.1.3.4. Algoritmo BP (Back-Propagation) con Diferencias Temporales

Como ya se mencionó al inicio, las entradas estarán asociadas a las características del objeto u obstáculo que se presentan al agente sobre el cual debe tomar una decisión y la salida deseada para cada una de estas entradas será calculada tomando como referencia la ecuación 3.16. Pero, ya se mencionó que ésta nos sirve para datos tomados de una secuencia de observaciones, por lo que se conocen los estados siguientes y las salidas para cada uno de los estados. En nuestro caso los datos no son tomados de una secuencia de observaciones, un estado no depende de otros por lo tanto  $\lambda = 0$ , no se conocen las salidas en cada estado. Por lo tanto,  $Y(t + 1)$  y  $Y(t)$  son igual a 0. En consecuencia la ecuación 3.16 quedaría del siguiente modo:

$$D(t) = \alpha * R(t) \tag{3.27}$$

El proceso de aprendizaje para este modelo, se hace por épocas. Durante cada época será presentado uno a uno los vectores de entrada para el entrenamiento de la red, con esto se obtiene la función de propagación, la función de activación y por último la salida de la red conocida como predicción. Con ésta podemos calcular el error entre la salida deseada y la predicción para poder actualizar los pesos sinápticos y pesos de vecindario de sinapsis  $N_j$  hasta lograr que el error cometido sea 0.

Para dejar esto más claro, se presenta el mismo ejemplo que en el modelo RMCS (M. Rvachev, 2013) con los cambios correspondientes:

- Supongamos que al paciente se le presenta una moneda sobre la mesa, es decir el paciente debe tomar la moneda. Las neuronas sensoriales (neuronas de entrada), envían la información de que lo que se está observando es un objeto pequeño, redondo y que está sobre la mesa. Con esta información se realizan las conexiones neuronales necesarias para procesar y enviar esa información a las neuronas de la capa oculta (vecindarios de sinapsis), donde la información recibida es procesada calculando la función de propagación y a su vez la función de activación quien es la que decide si la nueva información es enviada a la neurona motora (neurona de salida) donde se obtiene la predicción. Con esta predicción y la salida deseada obtenemos el error cometido, que será disminuido al momento de actualizar los pesos sinápticos y de vecindario de sinapsis  $N_j$ . Estos pesos serán actualizados hasta que la red obtenga una predicción acertada, es decir cuando coincida con la salida deseada. De este modo es como la red estará aprendiendo.

En este modelo, la recompensa es asignada al hacer el cálculo de la salida deseada, es decir en este caso ya se le está diciendo a la red cual acción a elegir es la correcta para el objeto u obstáculo que se le presente.

En general, el aprendizaje de este modelo consiste en actualizar los pesos de sinapsis y los pesos de vecindario de sinapsis  $N_j$ , esta actualización se realiza con el algoritmo

### 3. DISEÑO DEL EXPERIMENTO

---

de diferencias temporales, hasta lograr que las predicciones sean igual que las salidas deseadas.

Para este caso, lo que la red aprende es a encontrar la mejor expresión del componente  $C_j$ , donde se tendrán los registros del total de sinapsis excitatorias e inhibitorias necesarias para lograr que las predicciones fueran acertadas.

El pseudocódigo del algoritmo de la red neuronal con el modelo BP con diferencias temporales se presenta en el Apéndice A, Sección A.2.

## 3.2. Obtención de datos para entrenamiento de las RNA

Para la obtención del conjunto de datos de entrada y salida para el entrenamiento y prueba de las redes neuronales, se plantean los escenarios para cada uno de los problemas, es decir, para el problema de la dificultad para caminar y la dificultad con tareas de motricidad fina en los que se encuentra el paciente, tomando en cuenta las acciones que realiza en cada una de estas situaciones una persona sana y el paciente analizado en este trabajo.

Con el planteamiento de cada uno de los escenarios en que se encuentra el paciente, identificamos los elementos del aprendizaje por refuerzo (agente, estados, acciones y recompensas), omitiendo la política ya que no tenemos un ambiente en específico donde podamos definir las reglas de cómo se moverá el agente y de este modo poder asignar probabilidades para cada acción, en otras palabras en nuestro caso los eventos son independientes, un estado no depende de otro.

### 3.2.1. Escenario para el problema: dificultad para caminar

El escenario que se plantea es:

El paciente se encuentra en un espacio en el que debe caminar para avanzar, durante su recorrido podrá encontrar cuatro diferentes tipos de obstáculos. El primer tipo de obstáculo se refiere a lo que el paciente puede visualizar frente a él que no le permita continuar de manera normal su recorrido, esto puede ser una piedra, un charco, etc. El segundo tipo de obstáculo se refiere al sonido que representa peligro para el paciente y que le impide continuar. El tercer tipo de obstáculo representa a algún individuo que observa fijamente al paciente y que causa una sensación de nervios en este, el cuarto y último tipo de obstáculo estará representado por la presencia de un animal como un perro.

Al encontrarse con cualquiera de los obstáculos ya descritos, el paciente puede sufrir de mioclonías leves que le permiten continuar aunque sea de una manera un poco

anormal, caer al piso debido a mioclonías severas y no permitirle continuar, detenerse hasta conseguir mantener la calma y poder continuar, caminar de manera normal y por último, no querer avanzar debido a la sensación de miedo que él percibe.

### 3.2.1.1. Identificación de los elementos del aprendizaje por refuerzo

#### Agente

Paciente (persona)

#### Obstáculos

- Piedra
- Sonido
- Individuo
- Perro

#### Estados

Los estados, son los obstáculos mencionados anteriormente, usaremos las características físicas de cada uno de ellos para poder representarlos, de modo que cuando una característica en particular esté presente la representaremos con un 1 y 0 cuando la característica no esté presente en el obstáculo que se muestra al paciente.

Usar las características físicas de cada uno de los obstáculos se debe a que las neuronas de la capa de entrada representan a las neuronas sensoriales, es decir lo que individuo puede observar y/o palpar.

En la tabla 3.1, se muestran las 12 características tomadas en cuenta para simular el problema de la dificultad para caminar en el paciente, indicando mediante un  $\times$  a qué obstáculos pertenece cada una de estas características.

### 3. DISEÑO DEL EXPERIMENTO

---

		Piedra	Sonido	Individuo	Perro
$X_1$	Superficie áspera	×			
$X_2$	No visible		×		
$X_3$	Mamífero			×	×
$X_4$	Ser vivo			×	×
$X_5$	Ser no vivo	×	×		
$X_6$	Humano			×	
$X_7$	Animal				×
$X_8$	Fijo en el piso	×			
$X_9$	En el aire		×		
$X_{10}$	Pequeño / Tono grave	×	×	×	×
$X_{11}$	Mediano / Tono medio	×	×	×	×
$X_{12}$	Grande / Tono agudo	×	×	×	×

**Tabla 3.1:** Características de los obstáculos

#### Acciones

Al presentarse cualquiera de los obstáculos ya mencionados al agente, es decir al paciente, se tienen cinco posibles acciones que puede elegir realizar:

- Sufrir de mioclonías leves que permiten continuar su recorrido.
- Caer al piso (debido a las mioclonías severas) y no poder avanzar.
- Caminar de manera normal y poder evitar (ignorar) el obstáculo.
- Detenerse hasta mantener la calma para poder continuar.
- Negarse a avanzar debido a la sensación de miedo.

Para el caso del modelo RMCS (M. Rvachev, 2013), las acciones representan cada una de las neuronas de salida de la red neuronal.

#### Asignación de Recompensas

De acuerdo a la acción elegida, se asigna el valor de la recompensa obtenida. Los tres tipos de recompensa que se tomarán en cuenta son los siguientes:

<b>Recompensa</b>	<b>Valor</b>
Recompensa positiva fuerte	0.75
Recompensa positiva débil	0.25
Recompensa negativa fuerte	-1

La asignación de estos valores para las recompensas están dados conforme al funcionamiento del modelo RMCS (M. Rvachev, 2013), este algoritmo fue tomado tal cual la filosofía de su autor, no se realizó ninguna modificación, en resumen el funcionamiento de este modelo se basa en conseguir activar las neuronas que producen una acción de salida correcta y desactivar aquellas con las que la acción de salida sea incorrecta, una neurona se activa cuando el valor de su peso sináptico es 1 y se desactiva cuando este valor es 0 por lo tanto con las recompensas positivas fuerte y débil conseguimos activar las neuronas y al presentarse una recompensa negativa esta neurona es desactivada de inmediato.

Por lo tanto la recompensa positiva fuerte será asignada en aquella acción que sea considerada la correcta, la recompensa positiva débil cuando la acción elegida sea tomada en cuenta como posible de suceder y la recompensa negativa fuerte se asignará a aquellas acciones que sean consideradas como incorrectas. Para aclarar, una acción correcta es lo que normalmente respondería una persona sana por ejemplo caminar de manera normal ante cualquier obstáculo, o en su caso una persona que sufrió un paro cardiorrespiratorio como caer o sufrir mioclonías, una acción incorrecta es lo contrario, es decir, lo que cualquiera de estos individuos no realizaría normalmente. A continuación, se explica a detalle cómo se hará la asignación de recompensas a cada una de las acciones para este caso.

Para el caso de una persona que no tiene una lesión cerebral, se contempla que ante cualquier obstáculo que se le presente, éste sepa responder con la acción de caminar de manera normal evitando o ignorando el obstáculo, por lo tanto, al elegir esta acción se asignaría una recompensa positiva fuerte (0.75), en el caso en que el obstáculo presentado sea de dimensión grande o de tono agudo si se tratara de sonido y se eligiera la acción de detenerse un momento para verificar que el obstáculo no presenta algún peligro, se asignará una recompensa positiva débil (0.25) ya que es una acción posible aún en una persona sana, para el resto de las acciones de ser elegidas se asignaría una recompensa negativa fuerte (-1) ya que son consideradas acciones incorrectas.

En el caso de una persona con lesión cerebral, esta asignación cambia ya que el paciente tratado para este trabajo sufre mioclonías leves con la mayoría de los obstáculos. Para este caso se contempla que ante cualquier obstáculo que se le presente, éste responda con la acción de caminar sufriendo mioclonías leves, por lo tanto, al elegir esta acción se asignaría una recompensa positiva fuerte (0.75), en el caso en que el obstáculo presentado sea de dimensión pequeña o tono grave hablando de sonido y se realizará la acción de caminar normal, también se asignará una recompensa positiva fuerte (0.75), ya que este tipo de obstáculo no causa mayor problema en el paciente, ante cualquier

### 3. DISEÑO DEL EXPERIMENTO

---

otro obstáculo la acción de caminar normal asignaría una recompensa negativa fuerte (-1), ya que después de sufrir un paro cardiorespiratorio el paciente ya no pudo realizar esta acción, para el resto de las acciones de ser elegidas se asignaría una recompensa positiva débil (0.25) ya que son consideradas acciones posibles de suceder aunque no con mucha frecuencia en el paciente.

Para el modelo Back-Propagation la asignación de recompensas queda como en la tabla 3.2.

Acción	Recompensa
Sufrir Mioclonías	-1
Caer al piso	-2
Caminar Normal	2
Detenerse	1
Negarse a Caminar	-3

**Tabla 3.2:** Recompensas de aprendizaje para dificultad al caminar para BP con Diferencias Temporales.

En las tablas 3.3 y 3.4, se tiene de manera más clara esta asignación, se marca con (C) a las acciones que son consideradas como la acción correcta para una persona sana y una con lesión cerebral.

Obstáculo	Característica	Sufrir mioclonías	Caer	Caminar Normal	Detenerse	Negarse a caminar
		$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$
Piedra	Pequeña	-1	-1	0.75 (C)	-1	-1
	Mediana	-1	-1	0.75 (C)	-1	-1
	Grande	-1	-1	0.75 (C)	0.25 (C)	-1
Sonido	Tono grave	-1	-1	0.75 (C)	-1	-1
	Tono medio	-1	-1	0.75 (C)	-1	-1
	Tono agudo	-1	-1	0.75 (C)	0.25 (C)	-1
Individuo	Pequeño	-1	-1	0.75 (C)	-1	-1
	Mediano	-1	-1	0.75 (C)	-1	-1
	Grande	-1	-1	0.75 (C)	0.25 (C)	-1
Perro	Pequeño	-1	-1	0.75 (C)	-1	-1
	Mediano	-1	-1	0.75 (C)	-1	-1
	Grande	-1	-1	0.75 (C)	0.25 (C)	-1

**Tabla 3.3:** Recompensas de aprendizaje y acciones de prueba correctas para persona normal.

## 3.2 Obtención de datos para entrenamiento de las RNA

Obstáculo	Característica	Sufrir mioclonías	Caer	Caminar Normal	Detenerse	Negarse a caminar
		$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$
Piedra	Pequeña	0.25	0.25	0.75 (C)	0.25	0.25
	Mediana	0.75 (C)	0.25	-1	0.25	0.25
	Grande	0.75 (C)	0.25	-1	0.25	0.25
Sonido	Tono grave	0.25	0.25	0.75 (C)	0.25	0.25
	Tono medio	0.75 (C)	0.25	-1	0.25	0.25
	Tono agudo	0.75 (C)	0.25	-1	0.25	0.25
Individuo	Pequeño	0.25	0.25	0.75 (C)	0.25	0.25
	Mediano	0.75 (C)	0.25	-1	0.25	0.25
	Grande	0.75 (C)	0.25	-1	0.25	0.25
Perro	Pequeño	0.25	0.25	0.75 (C)	0.25	0.25
	Mediano	0.75 (C)	0.25	-1	0.25	0.25
	Grande	0.75 (C)	0.25	-1	0.25	0.25

**Tabla 3.4:** Recompensas de aprendizaje y acciones de prueba correctas para persona que ha sufrido un paro cardiorespiratorio.

### 3.2.1.2. Definición de objetos de aprendizaje y prueba

Para poder definir los objetos de aprendizaje y prueba, comenzaremos definiendo las neuronas de entrada y salida de la red para el caso del modelo RMCS (M. Rvachev, 2013), en el modelo BP con diferencias temporales la salida cambiaría.

#### Definición de las neuronas de entrada

En la tabla 3.5, se observa la asignación binaria para cada una de las características de los obstáculos, podemos notar que cada uno de los obstáculos que se plantean en el problema consta de características únicas, estas nos ayudan a distinguir uno del otro para poder asignar la recompensa correcta de acuerdo al obstáculo presentado y a la acción seleccionada.

Las características significativas para el obstáculo piedra son:

- Superficie áspera
- Fijo en el piso

Mientras que para el obstáculo sonido son:

- No visible

### 3. DISEÑO DEL EXPERIMENTO

---

- En el aire

Para el obstáculo individuo son:

- Mamífero
- Humano

Mientras que para el obstáculo perro son:

- Mamífero
- Animal

Las características restantes son no significativas, pero de igual forma importantes para etiquetar cada uno de los diferentes tipos de obstáculos que se le presentarán al paciente. Al decir no significativas nos referimos a que no es una característica que define al objeto, por ejemplo, en el obstáculo piedra la característica dimensión (pequeña, mediana o grande) sea cual sea no hace que el obstáculo deje de ser una piedra.

Características	Representación binaria
Superficie áspera =	[1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0] $X_1$
No visible =	[0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0] $X_2$
Mamífero =	[0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0] $X_3$
Ser vivo =	[0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0] $X_4$
Ser no vivo =	[0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0] $X_5$
Humano =	[0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0] $X_6$
Animal =	[0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0] $X_7$
Fijo en el piso =	[0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0] $X_8$
En el aire =	[0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0] $X_9$
Pequeño / Tono grave =	[0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0] $X_{10}$
Mediano / Tono medio =	[0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0] $X_{11}$
Grande / Tono agudo =	[0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1] $X_{12}$

**Tabla 3.5:** Definición de las neuronas de entrada para obstáculos.

### Definición de las neuronas de Salida

En la tabla 3.6 se presenta la asignación binaria para el caso del modelo RMCS (M. Rvachev, 2013) que representan a cada una de las acciones que el paciente puede realizar al tener presente cualquiera de los cuatro obstáculos.

Acción	Representación Binaria	
Sufrir Mioclonías =	[1, 0, 0, 0, 0]	$Y_1$
Caer al Piso =	[0, 1, 0, 0, 0]	$Y_2$
Caminar Normal =	[0, 0, 1, 0, 0]	$Y_3$
Detenerse =	[0, 0, 0, 1, 0]	$Y_4$
Negarse a Caminar =	[0, 0, 0, 0, 1]	$Y_5$

**Tabla 3.6:** Definición de las neuronas de salida para obstáculos.

### Definición de objetos de aprendizaje

Haciendo distintas combinaciones lógicas entre las características, se obtienen el total de obstáculos posibles a presentarse.

De este total de combinaciones posibles una parte será asignada para la etapa de aprendizaje, en la que se le presentarán al paciente varias veces para que aprenda a elegir la acción correcta que le dará la mejor recompensa, el resto de las combinaciones se destina para la etapa de prueba.

En la tabla 3.7 se presentan los obstáculos para la etapa de aprendizaje. La representación binaria se obtiene de la siguiente manera:

El total de características son 12, por lo tanto cada uno de los obstáculos será representado por un vector de 12 entradas  $[X_1, X_2, \dots, X_{12}]$ , cualquiera de los obstáculos puede o no tener las 12 características. Tomando como referencia la asignación binaria que se hizo para cada una de estas características en la tabla 3.5 y por mencionar un ejemplo de esta asignación, tomamos el obstáculo "piedra pequeña", éste obstáculo tiene las características; superficie áspera, ser no vivo, fijo en el piso y pequeña, que están representadas por  $X_1, X_5, X_8, X_{10}$ , representamos con un 1 en la entrada correspondiente cuando la característica  $X_i$  se presente en el obstáculo observado, en este caso el obstáculo piedra pequeña queda representado por el vector  $[1, 0, 0, 0, 1, 0, 0, 1, 0, 1, 0, 0]$ .

### 3. DISEÑO DEL EXPERIMENTO

---

<b>Obstáculo</b>	<b>Representación Binaria</b>
Piedra pequeña =	[1, 0, 0, 0, 1, 0, 0, 1, 0, 1, 0, 0]
Perro grande =	[0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 0, 1]
Sonido tono medio =	[0, 1, 0, 0, 1, 0, 0, 0, 1, 0, 1, 0]
Individuo pequeño =	[0, 0, 1, 1, 0, 1, 0, 0, 0, 1, 0, 0]
Piedra mediana =	[1, 0, 0, 0, 1, 0, 0, 1, 0, 0, 1, 0]
Perro mediano =	[0, 0, 1, 1, 0, 0, 1, 0, 0, 0, 1, 0]
Sonido tono agudo =	[0, 1, 0, 0, 1, 0, 0, 0, 1, 0, 0, 1]
Individuo grande =	[0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 0, 1]

**Tabla 3.7:** Obstáculos para etapa de aprendizaje.

#### Definición de objetos de prueba

En la etapa de prueba, se le presentarán al paciente los obstáculos de la tabla 3.8 para calificar el desempeño obtenido en la etapa de aprendizaje.

La asignación binaria se realiza de la misma forma que en los objetos de aprendizaje.

<b>Obstáculo</b>	<b>Representación Binaria</b>
Piedra grande =	[1, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 1]
Perro pequeño =	[0, 0, 1, 1, 0, 0, 1, 0, 0, 1, 0, 0]
Sonido tono grave =	[0, 1, 0, 0, 1, 0, 0, 0, 1, 1, 0, 0]
Individuo mediano =	[0, 0, 1, 1, 0, 1, 0, 0, 0, 0, 1, 0]

**Tabla 3.8:** Obstáculos para etapa de prueba.

### 3.2.2. Escenario para el problema: dificultad con tareas de motricidad fina

El escenario que se plantea es:

El paciente se encuentra un escenario en el que puede recibir de una persona, tomar de la mesa, dar a una persona o poner sobre la mesa tres objetos diferentes: una moneda, una pluma o un insecto.

Al realizar cualquiera de estas acciones, el paciente puede sujetar de manera normal, sufrir de mioclonías al intentar sujetar, tirar el objeto debido a las mioclonías severas o simplemente negarse a sujetar cualquiera de los tres objetos propuestos.

#### 3.2.2.1. Identificación de los elementos del aprendizaje por refuerzo

##### Agente

Paciente (persona)

##### Objetos

- Moneda
- Pluma
- Insecto

##### Estados

En este caso, los estados estarán representados por los ya mencionados objetos, usando las características físicas de cada uno de ellos para poder representarlos. De igual modo que en el problema anterior, cuando una característica en particular esté presente, la representaremos con un 1 y 0 cuando esta característica no esté presente en el objeto que será mostrado al paciente.

Al igual que en caso anterior definimos los estados usando las características físicas de los objetos ya que están representando a las neuronas sensoriales, es decir lo que el individuo observa y/o puede palpar.

En la tabla 3.9, se muestran las 12 características tomadas en cuenta para simular el problema con tareas de motricidad fina en el paciente, se indica con un  $\times$  a qué objeto pertenece cada una de estas características.

### 3. DISEÑO DEL EXPERIMENTO

---

		Moneda	Pluma	Insecto
$X_1$	Redonda	×		
$X_2$	Cilíndrica		×	
$X_3$	Invertebrado			×
$X_4$	Posee movimiento			×
$X_5$	No posee movimiento	×	×	
$X_6$	Ser vivo			×
$X_7$	Ser no vivo	×	×	
$X_8$	Pequeño	×		×
$X_9$	Mediano		×	×
$X_{10}$	Objeto sobre la mesa	×	×	×
$X_{11}$	Objeto sujetado por una persona	×	×	×
$X_{12}$	Objeto sujetado por el paciente	×	×	×

**Tabla 3.9:** Características de los objetos

#### Acciones

Al presentarse cualquiera de los objetos al paciente o dicho de otro modo, al agente, se tienen cuatro posibles acciones que puede elegir realizar:

- Sujetar el objeto de manera normal.
- Sufrir de mioclonías mientras sujeta el objeto.
- Tirar el objeto debido a mioclonías severas.
- No sujetar el objeto.

Al igual que en el problema anterior, aquí también las acciones representan cada una de las neuronas de salida de la red neuronal del modelo RMCS (M. Rvachev, 2013).

#### Asignación de Recompensas

De acuerdo a la acción elegida se asigna el valor de la recompensa obtenida. Los tres tipos de recompensa que se tomarán en cuenta son los mismos que en el problema anterior:

<b>Recompensa</b>	<b>Valor</b>
Recompensa positiva fuerte	0.75
Recompensa positiva débil	0.25
Recompensa negativa fuerte	-1

Al igual que en el escenario del problema anterior, estos valores son asignados debido al funcionamiento del modelo RMCS que ya fue explicado anteriormente.

La recompensa positiva fuerte será asignada en aquella acción que sea considerada la correcta. La recompensa positiva débil cuando la acción elegida sea tomada en cuenta como posible de suceder y la recompensa negativa fuerte se asignará a aquellas acciones que sean consideradas como incorrectas. A continuación, se explica a detalle cómo se hará la asignación de recompensas a cada una de las acciones para este caso. Del mismo modo que en el caso anterior, una acción correcta es lo que normalmente respondería una persona sana cómo sujetar de manera normal, o en su caso una persona que sufrió un paro cardiorrespiratorio sujetar sufriendo mioclonías, una acción incorrecta es lo contrario, lo que cualquiera de estos individuos no realizaría normalmente. A continuación se explica a detalle cómo se hará la asignación de recompensas a cada una de las acciones para este caso.

Para el caso de una persona que no tiene una lesión cerebral, se contempla que ante cualquier objeto que se le presente, éste sepa responder con la acción de sujetar de manera normal, por lo tanto, al elegir esta acción se asignaría una recompensa positiva fuerte (0.75), en el caso en que el objeto presentado sea un insecto pequeño y se eligiera la acción de tirarlo, se asignará una recompensa positiva débil (0.25) ya que es una acción posible aún en una persona sana, para el resto de las acciones, de ser elegidas se asignaría una recompensa negativa fuerte (-1) ya que son consideradas acciones incorrectas.

En el caso de una persona con lesión cerebral, esta asignación cambia; ya que el paciente tratado para este trabajo sufre mioclonías leves al querer sujetar cualquiera de los objetos. Para este caso se contempla que ante cualquier objeto que se le presente, éste responda con la acción de sufrir mioclonías leves al sujetar por lo tanto al elegir esta acción se asignaría una recompensa positiva fuerte (0.75); en el caso en que el objeto presentado sea un insecto pequeño y se realizara la acción de tirarlo, también se asignará una recompensa positiva fuerte (0.75), ante cualquier otro objeto, la acción de sujetar normal asignaría una recompensa negativa fuerte (-1), ya que después de sufrir un paro cardiorrespiratorio el paciente ya no pudo realizar esta acción; para el caso en que el objeto sea un insecto mediano y se eligiera la acción de tirarlo se asignaría una recompensa positiva débil (0.25), ya que son consideradas acciones posibles de suceder aunque no con mucha frecuencia en el paciente.

Para el modelo Back-Propagation la asignación de recompensas queda como en la tabla 3.10.

### 3. DISEÑO DEL EXPERIMENTO

---

Acción	Recompensa
Sujetar Normal	2
Sufrir Mioclonías	-1
Tirar el Objeto	1
No sujetar	-2
Negarse a Caminar	-3

**Tabla 3.10:** Recompensas de aprendizaje para dificultad con tareas de motricidad fina para BP con Diferencias Temporales.

En las tablas 3.11 y 3.12 se tiene de manera más clara esta asignación, se marca con (C) a las acciones que son consideradas como la acción correcta para una persona sana y una con lesión cerebral.

Objeto	Característica	Sujetar Normal	Sufrir mioclonías	Tirar	No sujetar
		$Y_1$	$Y_2$	$Y_3$	$Y_4$
Moneda	Pequeño	0.75 (C)	-1	-1	-1
Pluma	Mediano	0.75 (C)	-1	-1	-1
Insecto	Pequeño	0.75 (C)	-1	0.25	-1
	Mediano	0.75 (C)	-1	-1	-1

**Tabla 3.11:** Recompensas de aprendizaje y acciones de prueba correctas para persona normal.

Objeto	Característica	Sujetar Normal	Mioclonías	Tirar	No sujetar
		$Y_1$	$Y_2$	$Y_3$	$Y_4$
Moneda	Pequeño	-1	0.75 (C)	-1	-1
Pluma	Mediana	-1	0.75 (C)	-1	-1
Insecto	Pequeño	-1	0.75 (C)	0.75 (C)	-1
	Mediano	-1	0.75 (C)	0.25	-1

**Tabla 3.12:** Recompensas de aprendizaje y acciones de prueba correctas para persona que sufrió un paro cardiorrespiratorio.

### 3.2.2.2. Definición de objetos de aprendizaje y prueba

Para poder definir los objetos de aprendizaje y prueba, comenzaremos definiendo las neuronas de entrada y salida de la red para el caso del modelo RMCS, en el modelo BP con diferencias temporales la salida se calcula de manera diferente.

#### Definición de las neuronas de entrada

En la tabla 3.13, se observa la asignación binaria para cada una de las características de los objetos, podemos notar que cada uno de los objetos que se plantean en el problema consta de características únicas, estas nos ayudan a distinguir uno del otro para poder asignar la recompensa correcta de acuerdo al objeto presentado y a la acción seleccionada.

Las características significativas para el objeto moneda son:

- Redonda
- No posee movimiento
- Ser no vivo

Mientras que para el objeto pluma son:

- Cilíndrica
- No posee movimiento
- Ser no vivo

Por lo tanto para el objeto insecto son:

- Invertebrado
- Posee movimiento
- Ser vivo

Las características restantes, son no significativas pero de igual forma importantes para etiquetar cada uno de los diferentes tipos de objeto que se le presentarán al paciente. En este caso, por no significativas nos referimos a las características que sea cual sea la que se tome no hace que el objeto deje de ser ese objeto, por ejemplo la dimensión del objeto o el lugar donde éste se encuentre.

### 3. DISEÑO DEL EXPERIMENTO

---

Características	Representación Binaria	
Redonda =	[1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]	$X_1$
Cilíndrica =	[0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0]	$X_2$
Invertebrado =	[0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0]	$X_3$
Posee movimiento =	[0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0]	$X_4$
No posee movimiento =	[0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0]	$X_5$
Ser vivo =	[0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0]	$X_6$
Ser no vivo =	[0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0]	$X_7$
Pequeño =	[0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0]	$X_8$
Mediano =	[0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0]	$X_9$
Objeto sobre la mesa =	[0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0]	$X_{10}$
Objeto sujetado por una persona =	[0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0]	$X_{11}$
Objeto sujetado por el paciente =	[0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1]	$X_{12}$

**Tabla 3.13:** Definición de las neuronas de entrada para objetos.

#### Definición de las neuronas de salida

En la tabla 3.14, se presenta la asignación binaria para el caso del modelo RMCS que representan a cada una de las acciones que el paciente puede realizar al tener presente cualquiera de los cuatro objetos.

Acción	Representación binaria	
Sujetar Normal =	[1, 0, 0, 0]	$Y_1$
Sufrir Mioclonías =	[0, 1, 0, 0]	$Y_2$
Tirar el Objeto =	[0, 0, 1, 0]	$Y_3$
No Sujetar =	[0, 0, 0, 1]	$Y_4$

**Tabla 3.14:** Definición de las neuronas de salida para objetos.

### Definición de objetos de aprendizaje

De igual manera que en el caso anterior, se realizan distintas combinaciones lógicas entre las características de los objetos, al obtener el total de objetos posibles, se asigna una parte para la etapa de aprendizaje donde se espera que el paciente aprenda a identificar la acción correcta que genere la mayor recompensa posible.

En la tabla 3.15 se presentan los objetos para la etapa de aprendizaje. La representación binaria se obtiene de la siguiente manera:

El total de características son 12, por lo tanto cada uno de los objetos será representado por un vector de 12 entradas  $[X_1, X_2, \dots, X_{12}]$ , cualquiera de los objetos puede o no tener las 12 características. Tomando como referencia la asignación binaria que se hizo para cada una de estas características en la tabla 3.13 y por mencionar un ejemplo de esta asignación, tomamos el objeto "moneda sobre la mesa", éste obstáculo tiene las características; redonda, no posee movimiento, ser no vivo, pequeña y objeto sobre la mesa, que están representadas por  $X_1, X_5, X_7, X_8, X_{10}$ . Representamos con un 1 en la entrada correspondiente cuando la característica  $X_i$  se presente en el obstáculo observado, en este caso el objeto moneda sobre la mesa queda representado por el vector  $[1, 0, 0, 0, 1, 0, 1, 1, 0, 1, 0, 0]$

Objeto	Representación Binaria
Moneda sobre la mesa =	$[1, 0, 0, 0, 1, 0, 1, 1, 0, 1, 0, 0]$
Insecto pequeño sobre la mesa =	$[0, 0, 1, 1, 0, 1, 0, 1, 0, 1, 0, 0]$
Pluma sujeta por persona =	$[0, 1, 0, 0, 1, 0, 1, 0, 1, 0, 1, 0]$
Insecto mediano sujeta por paciente =	$[0, 0, 1, 1, 0, 1, 0, 0, 1, 0, 0, 1]$
Moneda sujeta por paciente =	$[1, 0, 0, 0, 1, 0, 1, 1, 0, 0, 0, 1]$
Insecto mediano sujeta por persona =	$[0, 0, 1, 1, 0, 1, 0, 0, 1, 0, 1, 0]$
Pluma sobre la mesa =	$[0, 1, 0, 0, 1, 0, 1, 0, 1, 1, 0, 0]$
Insecto pequeño sujeta por persona =	$[0, 0, 1, 1, 0, 1, 0, 1, 0, 0, 1, 0]$

Tabla 3.15: Objetos para etapa de aprendizaje.

### Definición de objetos de prueba

En la etapa de prueba, se presentaran al paciente los objetos de la tabla 3.16 para calificar el desempeño obtenido en la etapa de aprendizaje.

Objeto	Representación Binaria
Moneda sujetada por persona =	[1, 0, 0, 0, 1, 0, 1, 1, 0, 0, 1, 0]
Insecto pequeño sujetado por paciente =	[0, 0, 1, 1, 0, 1, 0, 1, 0, 0, 0, 1]
Pluma sujetada por paciente =	[0, 1, 0, 0, 1, 0, 1, 0, 1, 0, 0, 1]
Insecto mediano sobre la mesa =	[0, 0, 1, 1, 0, 1, 0, 0, 1, 1, 0, 0]

**Tabla 3.16:** Objetos para etapa de prueba.

### 3.3. Validación del modelo RMCS

Para este trabajo implementamos el modelo RMCS propuesto por Marat, reproducimos el modelo basándonos en el problema "Manzanas y Piedras" propuesto en la Sección 6 de (M. Rvachev, 2013).

El modelo BP, sólo se menciona como modelo de comparación contra el modelo RMCS, por lo tanto en esta sección presentamos únicamente los resultados obtenidos en la reproducción del problema "Manzanas y Piedras" con el modelo RMCS (M. Rvachev, 2013), que consiste en:

Un sujeto de prueba hambriento y sin entrenamiento tiene 12 neuronas sensoriales conectadas a 3 neuronas motoras. Todas las neuronas operan en un régimen de "on" o "off". El sujeto está sentado en una mesa en la que se colocan las manzanas (forma simétrica redondeada, tallo en la parte superior, superficie lisa) o piedras (forma simétrica redondeada, sin tallo en la parte superior, superficie rugosa), una a la vez.

Las manzanas y las piedras pueden ser de tamaños diferentes (pequeñas, medianas o grandes) y de 3 colores (rojo, amarillo o verde).

Cada una de las 3 neuronas motoras impulsa una acción: comer el objeto sobre la mesa, empujarlo fuera de la mesa o no hacer nada.

Cada una de las neuronas sensoriales se dispara si su característica de objeto asignado está presente: forma redondeada, forma simétrica, tallo en la parte superior, sin tallo en la parte superior, superficie lisa, superficie rugosa, color rojo, amarillo o verde, tamaño pequeño, mediano o grande (el total de 12 características, una característica por neurona sensorial).

Las neuronas sensoriales se conectan a las neuronas motoras en ubicaciones alea-

torias, formando 10,000 clusters sinápticos o vecindarios de sinapsis por cada neurona motora, cada vecindario tiene 4 sinapsis excitatorias provenientes de las neuronas sensoriales. Un vecindario de sinapsis se define como excitado si todas sus conexiones sinápticas están excitadas es decir tiene valor de 1.

A cada vecindario de sinapsis se le asigna inicialmente un peso de 0. Una neurona de salida se dispara si al menos 70 de sus vecindarios de sinapsis correspondientes tienen peso de al menos 1 es decir están excitados.

Se genera una recompensa positiva por comer una manzana o empujar una piedra fuera de la mesa. Se genera una recompensa negativa por comer una piedra, no hacer nada o realizar más de una acción simultáneamente.

Después de colocar un objeto en la mesa, el sujeto intenta ejecutar una acción memorizada. Si no hay ninguna acción memorizada (es decir, se excitan menos de 70 clusters con el peso de al menos 1 en cada una de las neuronas motoras) se activa una neurona motora aleatoria en un disparo de prueba, es decir se elige una acción al azar.

Específicamente, se presentó al sujeto una secuencia aleatoria de 8 objetos: manzana roja pequeña, manzana amarilla pequeña, manzana roja mediana, piedra amarilla mediana, piedra verde mediana, piedra amarilla grande y piedra verde grande.

Después de cada presentación, se anotó si el sujeto habría tenido respuestas correctas (es decir, comer manzanas y empujar las piedras), si se hubieran examinado, a los 4 objetos de prueba: manzana verde grande, manzana roja grande, piedra roja pequeña y piedra amarilla mediana.

### 3.3.1. Resultados del problema: Manzanas y Piedras

#### Características generales de la red neuronal

La topología de la red neuronal consta de 3 capas, una capa de entrada, una capa oculta y una capa de salida donde:

- En la capa de entrada, se tienen 12 neuronas con estado binario (0 se refiere a que se encuentra inactiva, 1 indica que la neurona se encuentra activa), cada una de las neuronas representa una de las características de la manzana o la piedra mencionadas anteriormente.
- En la capa de salida, se tienen 3 neuronas que representan las posibles acciones que el individuo puede realizar, también definidas anteriormente.
- En la capa oculta se tienen 30,000 neuronas (10,000 por cada neurona de salida).
- Las neuronas de la capa oculta, tienen solamente 4 conexiones provenientes de las neuronas de entrada, estas conexiones pueden ser excitatorias representadas por 1 e inhibitorias representadas por -1.

### 3. DISEÑO DEL EXPERIMENTO

---

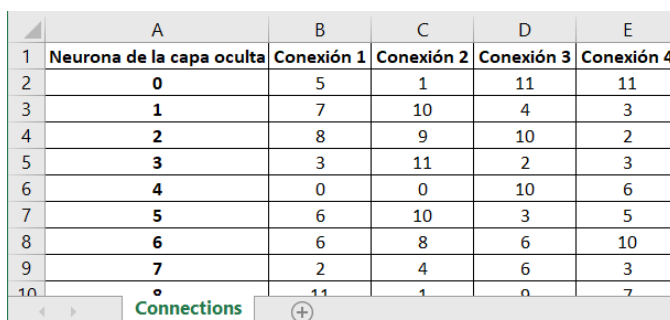
- Las conexiones entre la capa oculta y la capa de salida son 10,000 para cada neurona de salida, estas son tomadas en orden ascendente entre las neuronas de la capa oculta, es decir las primeras 10,000 neuronas solo se conectan con la primer neurona de salida, las siguientes 10,000 neuronas de la capa oculta sólo tienen conexión con la segunda neurona de la capa de salida y así sucesivamente.

#### Resumen de etapa de entrenamiento

El entrenamiento se lleva a cabo por simulaciones, con un total de 501 simulaciones (de la simulación 0 a la 500).

Para cada simulación:

- Se generaron los archivos correspondientes a las conexiones entre las neuronas de entrada y ocultas, con 4 conexiones en cada neurona de la capa oculta. Se tienen 501 archivos diferentes, generados de manera aleatoria. En la figura 3.8, se observa un ejemplo del contenido de estos archivos. En la primer columna se encuentra el número de neurona de la capa oculta al que nos referimos, en las columnas 2 a 5 se encuentran las conexiones, es decir en ellas se indica el número de neurona de entrada de la cual se está realizando la conexión en la neurona de la capa oculta, estos números van del 0 al 11 ya que son 12 neuronas de entrada.



	A	B	C	D	E
1	Neurona de la capa oculta	Conexión 1	Conexión 2	Conexión 3	Conexión 4
2	0	5	1	11	11
3	1	7	10	4	3
4	2	8	9	10	2
5	3	3	11	2	3
6	4	0	0	10	6
7	5	6	10	3	5
8	6	6	8	6	10
9	7	2	4	6	3
10	8	11	1	0	7

**Figura 3.8:** Ejemplo de archivo Connections.xlsx. En la primer columna se indica el número de neurona de la capa oculta o sea del vecindario de sinapsis  $N_j$  y en las columnas 2 a la 5 se indica el número de neurona de entrada con la que se está realizando la conexión sináptica en el respectivo vecindario de sinapsis.

- Se realizó la asignación de los pesos sinápticos para cada una de las conexiones, 1 se refiere a una conexión excitatoria y -1 a la conexión inhibitoria. En este caso todas las conexiones sinápticas fueron excitatorias.
- Se asigna el estado inicial de las neuronas de entrada, para nuestro caso se asignaron todas inactivas, es decir con un valor de 0.

4. Se realizaron 168 presentaciones aleatorias de los 8 objetos de aprendizaje definidos anteriormente. Se estableció una semilla de número aleatorio para que en cada simulación los objetos de aprendizaje sean presentados siempre en el mismo orden y se pueda observar los distintos comportamientos de aprendizaje dadas las mismas circunstancias en cuanto al orden de presentaciones pero con las conexiones distintas en cada simulación. A continuación se explicarán las características generales de estas presentaciones del objeto de aprendizaje.

#### **Presentación de los objetos de aprendizaje**

Para cada una de las 168 presentaciones aleatorias de los objetos de aprendizaje:

1. Se obtiene la salida activa de la red neuronal en respuesta al objeto presentado, esta salida se elige de acuerdo con la siguiente regla:

*Se obtiene el peso sináptico de cada una de las neuronas de la capa oculta (también llamadas vecindarios de sinapsis  $N_j$ ) calculando el componente de memoria combinatoria  $C_j$ , si al menos 70 neuronas de la capa oculta para cada neurona de salida tienen peso sináptico igual a 1, entonces la neurona de salida correspondiente se activa, si el total de neuronas de la capa oculta con peso sináptico igual a 1 es menor a 70 se selecciona de manera aleatoria una salida para ser activada.*

2. Se obtiene la recompensa de acuerdo a la acción elegida, es decir de acuerdo a la neurona de salida activa.
3. Se actualizan los pesos sinápticos de las neuronas de la capa oculta con las consecuencias de las recompensas obtenidas.
4. Se realiza la presentación de los 4 objetos de prueba para ver cómo respondería el sujeto en ese punto del aprendizaje.

#### **Presentación de los objetos de prueba**

Para cada presentación del objeto de prueba:

1. Se obtiene la salida activa en respuesta al objeto presentado.
2. Se registra en el archivo de aprendizaje :
  - Número de respuestas donde se disparó (activó) una sola neurona de salida.
  - Número de respuestas correctas, definidas anteriormente
  - Cantidad de veces que comió una piedra
  - Cantidad de veces que tiró una manzana

Estos resultados se guardan en un archivo con el nombre de Learning\_RMCS\_AppleAndStone.xlsx resultados que serán abordados a detalle a continuación.

### 3. DISEÑO DEL EXPERIMENTO

---

Con los resultados del archivo “Learning\_RMCS\_AppleAndStone.xlsx” se obtuvo lo siguiente:

1. Aprendizaje promedio el cual es calculado por medio de aciertos acumulados, obtenidos en cada simulación.
2. Aprendizaje promedio total (entre las 501 simulaciones).
3. Gráficas del aprendizaje en cada simulación. Donde se registran:
  - CountHadOneFiringOutput: Número de respuestas donde se disparó (activo) una sola salida.
  - CountCorrectAnswers: Número de respuestas correctas.
  - CountPushedOffApples: Número de veces que empujó una manzana.
  - CountAteStones: Número de veces que comió una piedra.
4. Cada gráfica fue etiquetada de acuerdo a los siguientes criterios:

**NA**:No Aprendió

**AV**:Aprendizaje Válido

**ANV**:Aprendizaje No Válido

Al analizar el comportamiento del aprendizaje en cada una de las gráficas, se observó que la parte más importante del aprendizaje es el final de éste; por lo tanto, se considera importante las últimas 25 presentaciones de objetos, es decir, se observa el comportamiento del aprendizaje en el tiempo 143 al 168 y se consideran **NA** aquellas gráficas donde el aprendizaje no es estable o no se obtuvo ninguna respuesta correcta en el tiempo ya establecido, se etiquetan como **AV** aquellas gráficas que cumplan con un comportamiento estable por lo menos en el tiempo de aprendizaje establecido como válido y que el porcentaje de aprendizaje promedio sea igual o mayor a la media, o sea al aprendizaje promedio total (aprendizaje promedio de las 501 simulaciones) y por último, se consideran **ANV** las gráficas que presenten un comportamiento estable por lo menos en el tiempo de aprendizaje establecido como válido pero que el aprendizaje promedio sea menor a la media.

Uno de los puntos más importantes a considerar a cerca de los resultados obtenidos es el total de aciertos y errores obtenidos en cada una de las simulaciones ya que son los que realmente nos indican si logró aprender o no.

Generalmente para hacer esta clasificación se tomaría como medida de referencia la media más dos desviaciones estándar, sin embargo, aquí decidimos tomar solo la media ya que al generar de manera aleatoria distintas conexiones sinápticas al inicio de cada una de las simulaciones, los resultados finales en el aprendizaje

promedio de cada una de estas son muy variables, por este motivo el valor de la desviación estándar es alto y al tomar como medida de referencia la media más dos desviaciones estándar estamos dejando fuera muchas simulaciones en las que se obtuvieron solo aciertos pero que tienen un aprendizaje promedio bajo debido a que los aciertos no se dan desde un inicio de la etapa de aprendizaje y que por supuesto el total de aciertos se va dando poco a poco, es decir primero obtiene 1 acierto, más tarde incrementa a 2 y así sucesivamente.

No podemos quitar la importancia a este tipo de gráficas ya que en realidad el aprendizaje en cualquier ser humano se da de este modo y que en realidad son los casos más importantes para nosotros, porque es donde se consiguió encontrar la conexión neuronal que permite al individuo realizar las actividades de manera correcta.

5. Histograma de frecuencias para el total de respuestas correctas que logró aprender al final del aprendizaje en cada simulación.
6. Histograma de frecuencias del aprendizaje (%) obtenido en cada simulación. Para esto, se obtuvo el rango ( $\text{Rango} = \text{Dato Mayor} - \text{Dato Menor}$ ), el número de clases ( $K = \sqrt{\text{Total de datos}}$ ), obteniendo un total de 22 clases, con esto se obtuvo la longitud de la clase ( $L = \text{Rango} / K$ ) y finalmente se obtuvieron los intervalos de clase.

El total de gráficas y archivos con extensión .xlsx se podrá encontrar en OneDrive debido a que la cantidad total de gráficas es muy elevada y los archivos .xlsx son muy largos por lo tanto es complicado poder mostrarlos por completo en este documento, sin embargo se presentan ejemplos de cada uno de estos.

La liga para acceder a estos archivos es:

[https://comunidadunam.mx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25\\_comunidad\\_unam\\_mx/El7AYAq0N690t8003gKra0kBsiaFQiPc1Y94Wg1vjrfqWA](https://comunidadunam.mx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25_comunidad_unam_mx/El7AYAq0N690t8003gKra0kBsiaFQiPc1Y94Wg1vjrfqWA), podrás solicitar el acceso a [kkarinasanchez25@gmail.com](mailto:kkarinasanchez25@gmail.com).

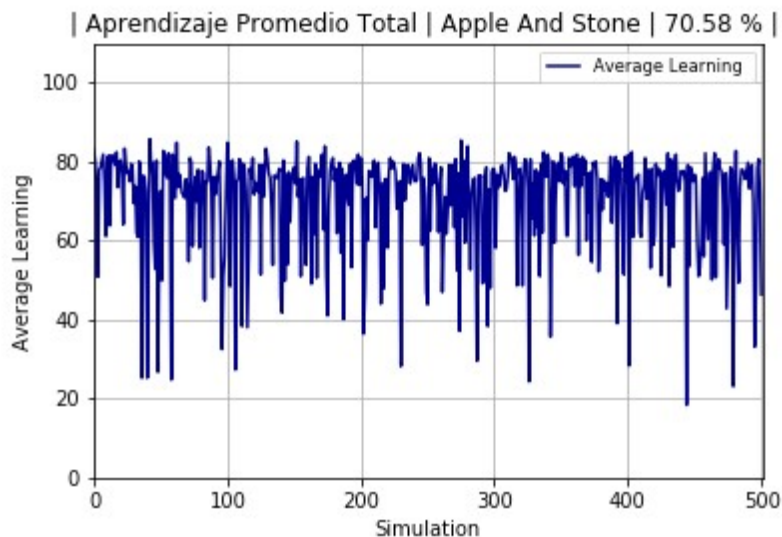
En el Apéndice A, sección A.8 se encuentra una descripción del contenido de cada carpeta y archivo.

### Presentación de los resultados

En la figura 3.9, se observa el aprendizaje promedio el cual es obtenido del total de aciertos acumulados en cada simulación, con esto se obtuvo un aprendizaje promedio total (entre las 501 simulaciones) de 70.58%, en general es un aprendizaje bajo, sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas y clasificado como **NA**, **AV** y **ANV** podemos ver que los resultados son favorables ya que en la mayoría de los casos se obtuvo un comportamiento catalogado como aprendizaje válido y fue una minoría en que se obtuvo un comportamiento en el que no aprendió.

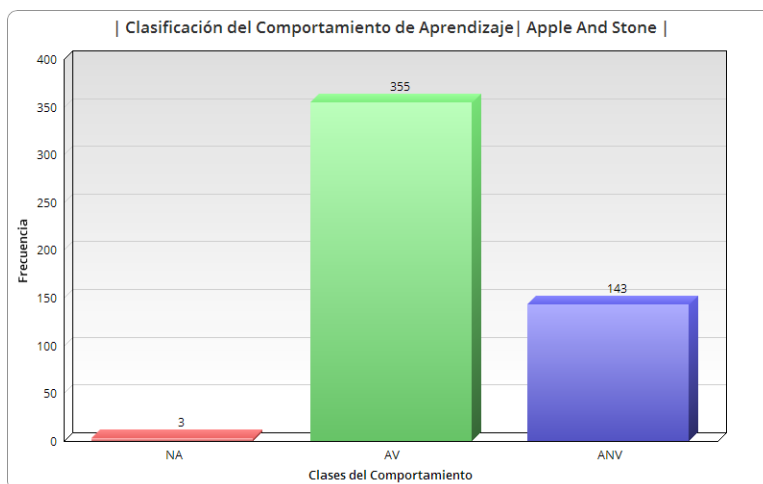
### 3. DISEÑO DEL EXPERIMENTO

---



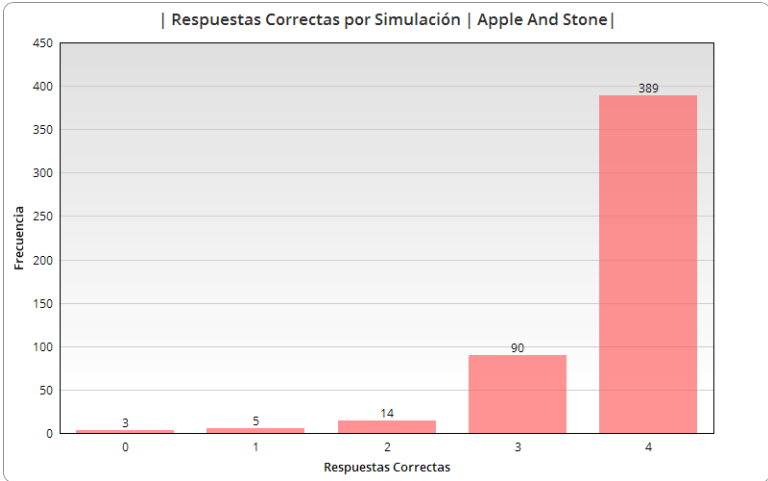
**Figura 3.9:** Gráfica del aprendizaje promedio para cada simulación.

En la figura 3.10 se muestra el total de simulaciones para la clasificación del comportamiento, se tuvieron 3 **NA**, 355 **AV** y 143 **ANV**.



**Figura 3.10:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para el problema “Manzanas y Piedras”

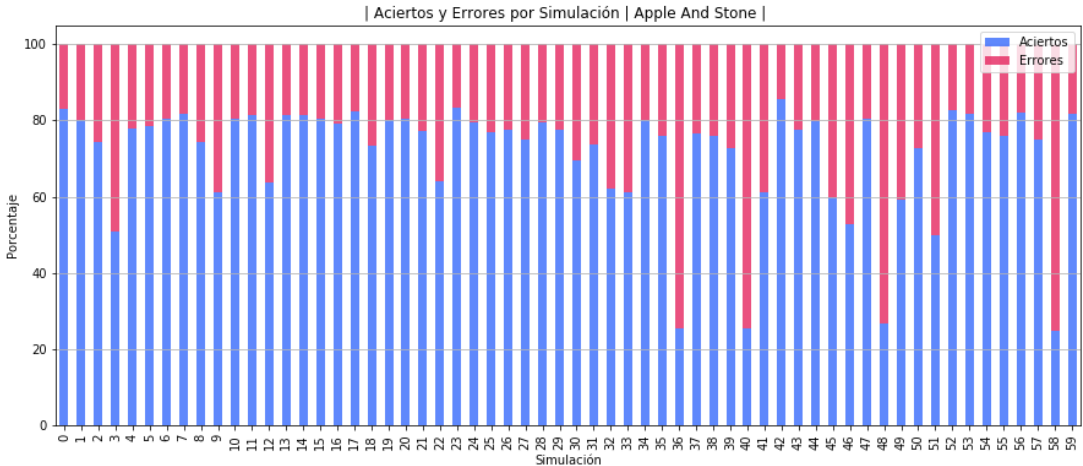
En la figura 3.11, se muestra el histograma de frecuencias del total de respuestas correctas que logró aprender al final del aprendizaje en cada simulación, se puede observar como en 389 simulaciones se obtuvieron las 4 respuestas correctas, que corresponde al 71 % del total de las simulaciones.



**Figura 3.11:** Histograma de frecuencias para el total de respuestas correctas aprendidas al final de cada simulación para el problema “Manzanas y Piedras”

El total de presentaciones en cada simulación es de 168 y después de cada presentación se esperarían los 4 aciertos, por lo tanto el total de aciertos esperados sería de 672. Por lo tanto obtener el total de aciertos acumulados durante las 168 presentaciones y presentarlo gráficamente sería difícil de poder apreciar debido a que son 501 simulaciones.

En la figura 3.12 se presentan en color azul el porcentaje de aciertos y en color rojo el de los errores de las primeras 60 simulaciones.




**Figura 3.12:** Porcentajes de aciertos y errores acumulados durante la etapa de aprendizaje en las primeras 60 simulaciones para el problema “Manzanas y Piedras”

### 3. DISEÑO DEL EXPERIMENTO

En las simulaciones en las que se observa que el porcentaje de errores es mayor, son los casos en que el aprendizaje requiere de más tiempo, es decir, comienza a reconocer los objetos y en consecuencia a elegir la acción correcta pero lo hace a partir de la presentación número 80, o sea casi después del 50 % del tiempo total de la etapa de aprendizaje.

Finalmente, en la figura 3.13 se presenta el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se concentra en los aprendizajes que van del 73.476 % al 82.647 % lo que es un buen aprendizaje, no sólo tomando en cuenta el valor del aprendizaje promedio, sino que se lograron aprender las 4 respuestas correctas.



**Figura 3.13:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para el problema “Manzanas y Piedras”

---

## Capítulo 4

# Análisis de resultados

---

En este capítulo se presenta un resumen acerca de los resultados obtenidos de las distintas redes neuronales implementadas con los modelos RMCS y BP con diferencias temporales, además del análisis que se realizó a los resultados del componente de memoria combinatoria Cj. Se muestran distintas gráficas y tablas para ayudar al lector a tener una mejor comprensión de estos resultados. Al final del capítulo se tiene una sección en la que se incluye una breve explicación acerca de la interpretación de los resultados ya presentados.

Para una mejor comprensión del análisis de los resultados obtenidos, se comenzará con una amplia explicación sobre los pasos que se llevaron a cabo durante la etapa de entrenamiento de cada una de las redes neuronales para los dos problemas tratados en este trabajo.

Para identificar los resultados de cada problema usamos la palabra “Obstacles” para el problema de dificultad al caminar y “Objects” para el problema de dificultad con tareas de motricidad fina. Cuando se refiere a un individuo normal (sano) usamos “PNormal” y para un individuo que sufrió un paro cardiorrespiratorio usamos “PPCR”. Finalmente para indicar los distintos porcentajes en las conexiones sinápticas usamos “Synaptic excitatorias(%) -inhibitorias(%)”, la asignación de los distintos porcentajes se realiza con el fin de verificar con cuál de ellos se obtienen resultados más satisfactorios.

### 4.1. Resumen de entrenamiento de RMCS

#### **Características generales de las redes neuronales:**

La topología de la red neuronal consta de 3 capas, una capa de entrada, una capa oculta y una capa de salida donde:

- En la capa de entrada se tienen 12 neuronas con estado binario (0 se refiere a que se encuentra inactiva, 1 indica que la neurona se encuentra activa), cada una

## 4. ANÁLISIS DE RESULTADOS

---

de las neuronas representa una de las características del obstáculo u objeto ya definidas en el capítulo 3, sección 3.2.1.1, tablas 3.1, 3.5 y sección 3.2.2.1, tablas 3.9, 3.13 respectivamente.

- En la capa de salida se tienen 5 y 4 neuronas para el problema de dificultad al caminar y con tareas de motricidad fina respectivamente, representan las posibles acciones que el individuo puede realizar, también definidas en el capítulo 3, sección 3.2.1.1, tabla 3.6 y sección 3.2.2.1, tabla 3.14.
- En la capa oculta se tienen 50,000 y 40,000 neuronas respectivamente para cada uno de los problemas tratados (10,000 por cada neurona de salida).
- Las neuronas de la capa oculta tienen solamente 4 conexiones provenientes de las neuronas de entrada, estas conexiones pueden ser excitatorias representadas por 1 e inhibitorias representadas por -1.

La decisión de tomar como máximo 4 conexiones se debe a que al tener un incremento en estas conexiones, el incremento en recursos computacionales era exageradamente alto. Se realizaron diferentes experimentos y si se hubiese tenido una conexión total de las 12 neuronas de entrada se hubiese necesitado una máquina con capacidad de 22 TB en memoria RAM para poder realizar todos los cálculos necesarios. Otro punto importante es que de acuerdo a las características definidas para cada uno de los objetos de aprendizaje, 4 características son suficientes para poder identificar el objeto.

- Las conexiones entre la capa oculta y la capa de salida son 10,000 para cada neurona de salida, estas son tomadas en orden ascendente entre las neuronas de la capa oculta, es decir las primeras 10,000 neuronas solo se conectan con la primer neurona de salida, las siguientes 10,000 neuronas sólo tienen conexión con la segunda neurona de la capa de salida y así sucesivamente.

### **Resumen de etapa de entrenamiento**

El entrenamiento se lleva a cabo por simulaciones, con un total de 251 simulaciones por red neuronal artificial (de la simulación 0 a la 250).

Para cada simulación:

1. Se generaron los archivos correspondientes a las conexiones entre las neuronas de entrada y ocultas, con 4 conexiones en cada neurona de la capa oculta. Se tienen 251 archivos diferentes, generados de manera aleatoria. En el Apéndice A, sección A.3 y A.5 se muestra el código con que fueron generados estos archivos.

En la figura 4.1 se observa una parte de la versión final del contenido de estos archivos. En la primer columna se encuentra el número de neurona de la capa

oculta al que nos referimos, en las columnas 2 a 5 se encuentran las conexiones, es decir, en ellas se indica el número de neurona de entrada de la cual se está realizando la conexión en la neurona de la capa oculta, estos números van del 0 al 11 ya que son 12 neuronas de entrada. Como podemos observar en una neurona de la capa oculta se pueden tener más de una conexión de una neurona de entrada, ya que a cada una de estas conexiones se le puede asignar distinto peso sináptico.

	A	B	C	D	E
1	<b>Neurona de la capa oculta</b>	<b>Conexión 1</b>	<b>Conexión 2</b>	<b>Conexión 3</b>	<b>Conexión 4</b>
2	0	5	1	11	11
3	1	7	10	4	3
4	2	8	9	10	2
5	3	3	11	2	3
6	4	0	0	10	6
7	5	6	10	3	5
8	6	6	8	6	10
9	7	2	4	6	3
10	8	11	1	0	7

**Figura 4.1:** Ejemplo del contenido en el archivo Connections.xlsx. En la primer columna se indica el número de neurona de la capa oculta o sea del vecindario de sinapsis  $N_j$  y en las columnas 2 a la 5 se indica el número de neurona de entrada con la que se está realizando la conexión sináptica en el respectivo vecindario de sinapsis.

2. Se generaron los archivos correspondientes a la asignación de los pesos sinápticos para cada una de las conexiones, 1 se refiere a una conexión excitatoria y -1 a la conexión inhibitoria.

Para el problema de la dificultad para caminar se tiene un total de 200,000 conexiones sinápticas para las 50,000 neuronas de la capa oculta y para la dificultad con tareas de motricidad fina se tienen 160,000 conexiones sinápticas para las 40,000 neuronas de la capa oculta, de esos totales se asignaron distintos porcentajes para la asignación de estos pesos sinápticos con el fin de verificar con cuál de ellos se obtienen resultados más satisfactorios, estos porcentajes son 10 % excitatorias - 90 % inhibitorias, 20 % - 80 %, 30 % - 70 %, 40 % - 60 %, 50 % - 50 %, 60 % - 40 %, 70 % - 30 %, 80 % - 20 %, 90 % - 10 % y finalmente 100 % excitatorias - 0 % inhibitorias.

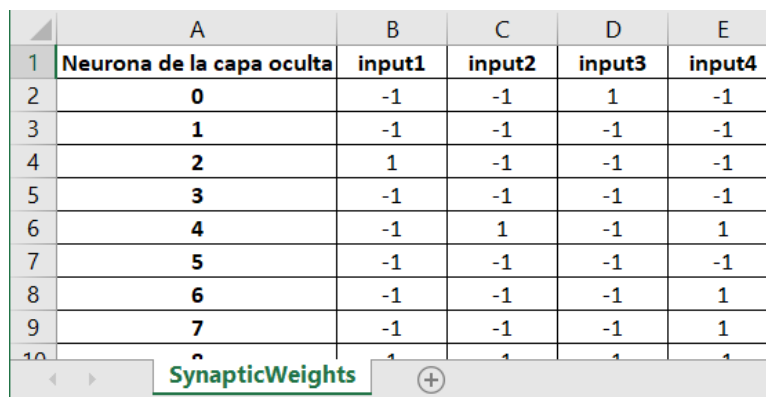
3. Se tienen 251 archivos diferentes llamados SynapticWeights.xlsx, uno para cada archivo Connections.xlsx, de igual manera fueron generados de manera aleatoria, en el Apéndice A sección A.4 y A.6 se muestra el código con el que fueron generados.

En la figura 4.2 se muestra una parte de la versión final de estos archivos. En la

#### 4. ANÁLISIS DE RESULTADOS

---

columna 1 se indica el número de neurona de la capa oculta, en las columnas 2 a 5 se indican los pesos de la conexiones asignadas en el archivo Connections.xlsx.



	A	B	C	D	E
1	Neurona de la capa oculta	input1	input2	input3	input4
2	0	-1	-1	1	-1
3	1	-1	-1	-1	-1
4	2	1	-1	-1	-1
5	3	-1	-1	-1	-1
6	4	-1	1	-1	1
7	5	-1	-1	-1	-1
8	6	-1	-1	-1	1
9	7	-1	-1	-1	1
10	8	1	1	1	1

Figura 4.2: Ejemplo del contenido en el archivo SynapticWeights.xlsx

4. Se asignó el estado inicial de las neuronas de entrada, para nuestro caso se asignaron todas inactivas, es decir con un valor de 0.
5. Se calculó el componente de memoria combinatoria  $C_j$ . Al tener como estado inicial las neuronas de entrada inactivas, el valor del componente  $C_j$  es 0. Este resultado se guarda en un archivo “*CombinatorialMemoryComponent.xlsx*”.

Durante el proceso de entrenamiento estas conexiones se van activando al ser presentados cada uno de los objetos de aprendizaje y por lo tanto el valor del componente  $C_j$  cambia. En el Apéndice A sección A.7 se encuentra un análisis general del componente de memoria combinatoria  $C_j$ .

6. Se realizaron 200 presentaciones aleatorias de los 8 objetos de aprendizaje definidos en las tablas 3.7 y 3.15 respectivamente para cada problema tratado en esta tesis.

Se estableció una semilla de número aleatorio para que en cada simulación los objetos de aprendizaje sean presentados siempre en el mismo orden y se pueda observar los distintos comportamientos de aprendizaje dadas las mismas circunstancias en cuanto al orden de presentaciones, pero con las conexiones y los pesos sinápticos distintos en cada simulación. A continuación se explicarán las características generales de estas presentaciones del objeto de aprendizaje.

#### Presentación de los objetos de aprendizaje

En cada una de las 200 presentaciones aleatorias de los objetos de aprendizaje:

1. Se obtiene la salida activa de la red neuronal en respuesta al objeto presentado, esta salida se elige de acuerdo con la siguiente regla:

*Se obtiene el peso sináptico de cada una de las neuronas de la capa oculta (también llamadas vecindarios de sinapsis  $N_j$ ) calculando el componente de memoria combinatoria  $C_j$ , si al menos 70 neuronas de la capa oculta para cada neurona de salida tienen peso sináptico igual a 1, entonces la neurona de salida correspondiente se activa, si el total de neuronas de la capa oculta con peso sináptico igual a 1 es menor a 70 se selecciona de manera aleatoria una salida para ser activada.*

Se decidió tomar como límite 70 neuronas activas ya que es una cifra propuesta en (M. Rvachev, 2013), además se hicieron experimentos donde se incrementó y disminuyó la cifra pero el tiempo de aprendizaje era muy lento, es decir se requería aumentar el total de presentaciones para llegar a un punto de aprendizaje lo que a su vez aumentaba el tiempo de ejecución de cada una de las redes neuronales.

2. Se obtiene la recompensa de acuerdo a la acción elegida, es decir de acuerdo a la neurona de salida activa.
3. Se actualizan los pesos sinápticos de las neuronas de la capa oculta con las consecuencias de las recompensas obtenidas.
4. Se realiza la presentación de los 4 objetos de prueba para ver cómo respondería el sujeto en ese punto del aprendizaje.

### **Presentación de los objetos de prueba**

Para cada presentación del objeto de prueba:

1. Se obtiene la salida activa en respuesta al objeto presentado.
2. Se registra en el archivo de aprendizaje:
  - Número de respuestas donde se disparó (activó) una sola neurona de salida.
  - Número de respuestas correctas, definidas en las tablas 3.3, tabla 3.4, 3.11 y 3.12 para un individuo sano y para uno que sufrió un paro cardiorrespiratorio en los problemas de dificultad al caminar y con tareas de motricidad fina respectivamente.
  - Cantidad de veces que sufrió mioclonías al caminar o sujetar
  - Cantidad de veces que cae o tiró al piso el objeto
  - Cantidad de veces que caminó o sujeto normal
  - Cantidad de veces que se detuvo un momento al caminar
  - Cantidad de veces que se negó a avanzar o a sujetar

Estos resultados se guardan en un archivo con el nombre de Learning\_RMCS\_Obstacles.xlsx y Learning\_RMCS\_Objects.xlsx de acuerdo a cada problema.

### 4.2. Resultados de RMCS


Con los resultados de los archivos “Learning\_RMCS\_Obstacles.xlsx” y “Learning\_RMCS\_Objects.xlsx” para cada red neuronal artificial se obtuvo lo siguiente

#### 1. Aprendizaje promedio total

El aprendizaje promedio se calcula por medio del total de aciertos acumulados durante las 200 presentaciones en cada simulación, por lo tanto el aprendizaje promedio total es la media de los 251 aprendizajes promedio calculados anteriormente correspondientes al total de simulaciones.

En la figura 4.3 se muestra un ejemplo de estas gráficas. En el título de cada una de ellas se tiene el problema al que pertenece, el individuo analizado, el porcentaje del total de conexiones excitatorias- inhibitorias del experimento y finalmente el aprendizaje promedio total. En el eje horizontal del gráfico se presenta el número de simulación (de 0 a 250) y en el eje vertical se indica el aprendizaje promedio obtenido.

En la gráfica de la izquierda se presentan los resultados para las conexiones 40 % excitatorias - 60 % inhibitorias y en la de la derecha se tiene una conexión de 100 % excitatorias - 0 % inhibitorias. Podemos notar como en la primera el aprendizaje promedio total es muy bajo en comparación con el de la segunda gráfica. También observamos que en la primera se tiene una dispersión de los datos mucho mayor que en la segunda, esto se debe a que en cada simulación se generan de manera aleatoria las conexiones y sus respectivos pesos sinápticos.



**Figura 4.3:** Ejemplos de gráficos donde se registra el aprendizaje promedio en cada simulación y con esto se obtiene el aprendizaje promedio total.

Se realizaron histogramas de frecuencias para los aprendizajes promedio de cada simulación de acuerdo a los siguientes criterios:

1. Determinar el rango.

$$Rango = Dato Mayor - Dato Menor \quad (4.1)$$

Donde

$$Dato Mayor = 100, Dato Menor = 0, Rango = 100 - 0 = 100 \quad (4.2)$$

2. Obtener el número de clases.

$$K = \sqrt{Total\ de\ datos} \quad (4.3)$$

Donde

$$K = \sqrt{251} = 15.84, por\ lo\ tanto\ K = 16 \quad (4.4)$$

3. Longitud de la clase

$$L = Rango/K \quad (4.5)$$

por lo tanto

$$L = 100/16 = 6.25 \quad (4.6)$$

4. Construir los intervalos de clase. Se muestran en la tabla 4.1

Intervalo	Rango
1	[0 , 6.25]
2	(6.25 , 12.5]
3	(12.5 , 18.75]
4	(18.75 , 25]
5	(25 , 31.25]
6	(31.25 , 37.5]
7	(37.5 , 43.75]
8	(43.75 , 50]
9	(50 , 56.25]
10	(56.25 , 62.5]
11	(62.5 , 68.75]
12	(68.75 , 75]
13	(75 , 81.25]
14	(81.25 , 87.5]
15	(87.5 , 93.75]
16	(93.75 , 100]

**Tabla 4.1:** Intervalos de clase para histograma de frecuencias del aprendizaje promedio obtenido en cada simulación.

## 4. ANÁLISIS DE RESULTADOS

---

En general los valores obtenidos del aprendizaje promedio total de cada red neuronal fueron muy bajos, sin embargo, debíamos observar como fue el comportamiento de éste aprendizaje en cada una de las 251 simulaciones y para esto se realizó el siguiente paso.

### 2. Gráficas del aprendizaje en cada simulación.

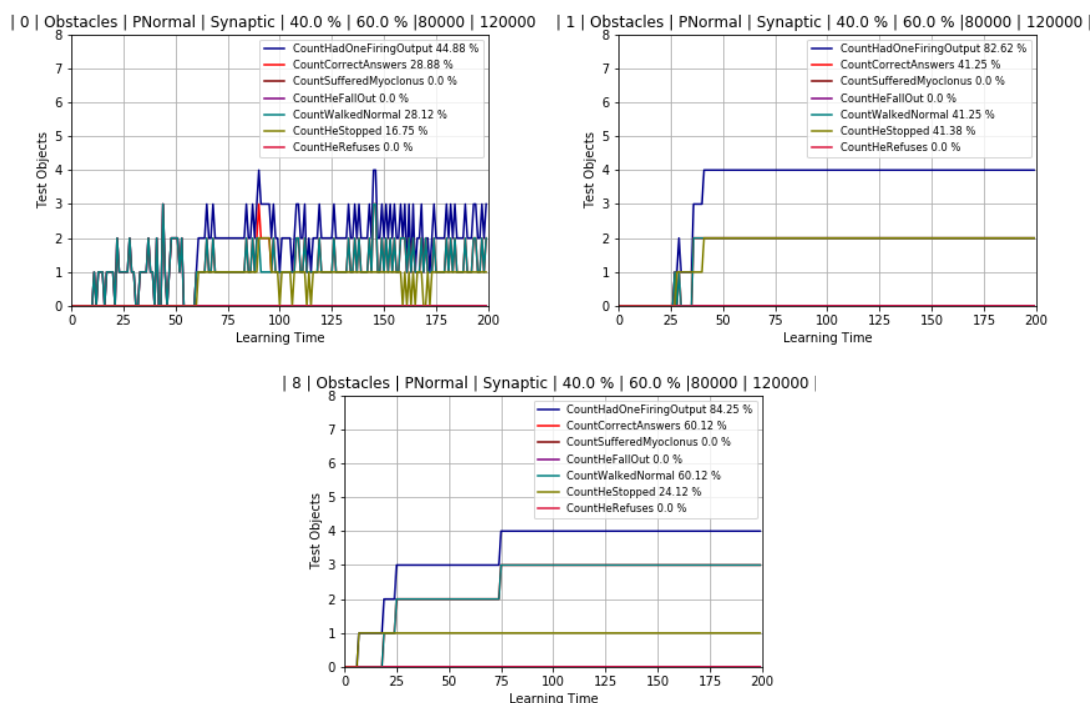
En estas gráficas se registraron:

- `CountHadOneFiringOutput`: Número de respuestas donde se disparó (activo) una sola salida.
- `CountCorrectAnswers`: Número de respuestas correctas.
- `CountSufferedMyoclonus`: Número de veces que sufrió mioclonías al caminar o sujetar.
- `CountHeFallOut`: Número de veces que cae o tiró al piso el objeto.
- `CountWalkedNormal`: Número de veces que caminó o sujetó normal.
- `CountHeStopped`: Número de veces que se detuvo un momento al caminar.
- `CountHeRefuses`: Número de veces que se negó a avanzar o a sujetar.

En la figura 4.4 se muestran ejemplos de estas gráficas, pertenecen al problema de “Obstacles” para “PNormal” con conexiones 40 % excitatorias - 60 % inhibitorias, mismo que se presentó en el punto anterior en la gráfica de la izquierda.

Realmente en estas gráficas es donde podemos observar cómo se fue comportando el aprendizaje. Tenemos que analizar esto como un comportamiento de aprendizaje humano, por ejemplo, cuando estamos aprendiendo a realizar distintas actividades desconocidas, al principio podemos fallar una y otra vez en una de las actividades o en todas, pero conforme pasa el tiempo nuestro cerebro va reteniendo conocimiento y además incrementándose hasta lograr realizar todas esas actividad sin ningún problema.

Por lo tanto ese mismo comportamiento es el que buscamos observar en estas gráficas porque eso nos indicaría que se consiguieron reforzar las conexiones sinápticas de manera adecuada para poder realizar de manera eficiente la actividad de caminar o de sujetar para cualquiera de los dos individuos, dependiendo las limitaciones de cada uno de ellos.



**Figura 4.4:** Ejemplos de gráficos donde se observan distintos comportamientos de aprendizaje.

Por lo tanto para poder distinguir entre un comportamiento y otro, se procedió al siguiente paso.

### 3. Clasificar y etiquetar distintos tipos de comportamientos de aprendizaje.

Para esto cada gráfica fue clasificada y etiquetada de acuerdo a los siguientes criterios:

- NA: No Aprendió
- AV: Aprendizaje Válido
- ANV: Aprendizaje No Válido

Al analizar el comportamiento del aprendizaje en cada una de las gráficas se observó que la parte más importante del aprendizaje es el final de éste, por lo tanto, se considera importante las últimas 25 presentaciones de objetos, es decir, se observa el comportamiento del aprendizaje en el tiempo 175 al 200 y se consideran **NA** aquellas gráficas donde el aprendizaje no es estable o no se obtuvo ninguna respuesta correcta en el tiempo ya establecido, se etiquetan como **AV** aquellas gráficas que cumplan con

#### 4. ANÁLISIS DE RESULTADOS

---

un comportamiento estable por lo menos en el tiempo de aprendizaje establecido como válido y que el porcentaje de aprendizaje promedio sea igual o mayor a la media, o sea al aprendizaje promedio total (aprendizaje promedio de las 251 simulaciones) y por último se consideran ANV las gráficas que presenten un comportamiento estable por lo menos en el tiempo de aprendizaje establecido como válido pero que el aprendizaje promedio sea menor a la media.

Uno de los puntos más importantes a considerar a cerca de los resultados obtenidos es el total de aciertos y errores obtenidos en cada una de las simulaciones ya que son los que realmente nos indican si logró aprender o no.

Generalmente para hacer esta clasificación se tomaría como medida de referencia la media más dos desviaciones estándar, sin embargo, aquí decidimos tomar solo la media ya que al generar de manera aleatoria distintas conexiones sinápticas al inicio de cada una de las simulaciones, los resultados finales en el aprendizaje promedio de cada una de estas son muy variables, por este motivo el valor de la desviación estándar es alto y al tomar como medida de referencia la media más dos desviaciones estándar estamos dejando fuera muchas simulaciones en las que se obtuvieron sólo aciertos pero que tienen un aprendizaje promedio bajo debido a que los aciertos no se dan desde un inicio de la etapa de aprendizaje y que por supuesto el total de aciertos se va dando poco a poco, es decir primero obtiene 1 acierto, más tarde incrementa a 2 y así sucesivamente.

No podemos quitar la importancia a este tipo de gráficas, como se mencionó anteriormente, en realidad el aprendizaje en cualquier ser humano se da de este modo y en realidad son los casos más importantes para nosotros, porque es donde se consiguió encontrar la conexión neuronal que permite al individuo realizar las actividades de manera correcta.

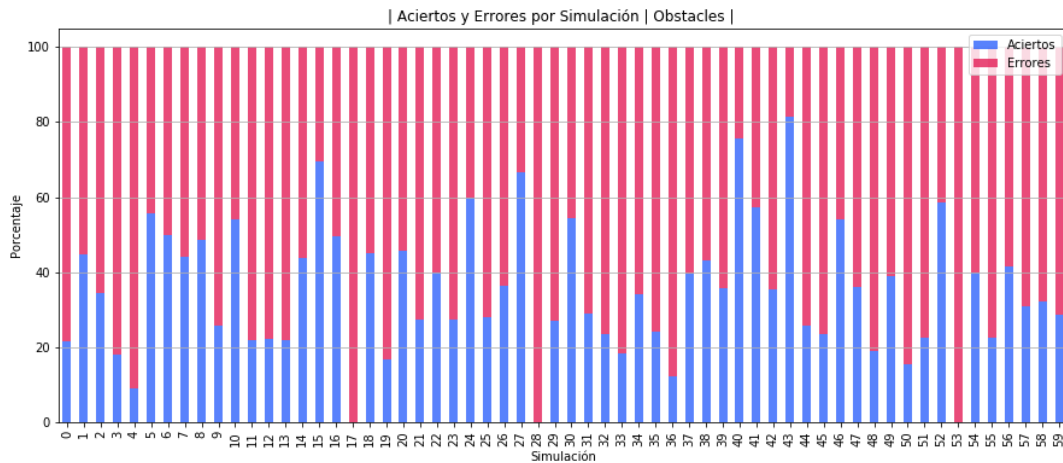
Con los resultados de esta clasificación se obtuvieron histogramas de frecuencias, en los que pudimos observar que mientras aumentan las conexiones excitatorias también aumentan los casos con comportamientos AV y como consecuencia van disminuyendo los casos con comportamiento NA. Además se realizaron los histogramas de frecuencias pero de únicamente los comportamientos estables, o sea los AV.

Después de esto, se procedió a realizar los siguiente.

#### **4. Registrar las respuestas correctas con las que concluyó el aprendizaje en cada simulación.**

El total de presentaciones en cada simulación es de 200 y después de cada presentación se esperarían los 4 aciertos, por lo que el total de aciertos esperados sería de 800. Por lo tanto obtener el total de aciertos acumulados durante las 200 presentaciones y mostrarlo gráficamente sería difícil de apreciar debido a que son muchas simulaciones.

En la figura 4.5 se muestra un ejemplo de cómo se vería gráficamente lo anterior, se presentan en color azul el porcentaje de aciertos y en color rojo el de los errores de las primeras 60 simulaciones.



**Figura 4.5:** Porcentajes de aciertos y errores acumulados durante la etapa de aprendizaje en las primeras 60 simulaciones para el problema “Dificultad al caminar”

En las simulaciones en las que se observa que el porcentaje de errores es mayor, son los casos en que no logró aprender nada o el aprendizaje requiere de más tiempo, es decir, comienza a reconocer los objetos y en consecuencia a elegir la acción correcta pero lo hace a partir de casi el 50 % del tiempo total de la etapa de aprendizaje.

Por la dificultad de observar de manera clara este tipo de gráficas es que se decidió tomar únicamente el total de aciertos obtenidos en la presentación 200, es decir al final del aprendizaje. Con esta información también se realizaron histogramas en los que se pudo apreciar nuevamente que al aumentar los comportamientos AV en estos se lograban obtener los 4 aciertos, por lo tanto se tenían comportamientos de aprendizaje estables, donde los aciertos se incrementaron conforme avanzaba el tiempo.

Visto esto de manera biológica, asociamos la estabilidad y el incremento en la cantidad de aciertos con la memoria de una persona, es decir aprendió a retener e incrementar información.

En el objetivo de este trabajo no solo buscamos modelos con un aprendizaje alto, sino que la parte más importante de analizar son los resultados del componente Cj, que es donde se tiene el registro del total de conexiones excitatorias e inhibitorias por lo tanto se realizó lo siguiente.

#### 4. ANÁLISIS DE RESULTADOS

##### Análisis del componente de memoria combinatoria Cj.

Para todos los distintos porcentajes en las conexiones sinápticas se tienen los archivos “CombinatorialMemoryComponent.xlsx” correspondientes al componente de memoria combinatoria para cada una de las 251 simulaciones de cada caso, estos fueron analizados y con esto se generó un archivo “Memoria Combinatoria.xlsx”, donde se tiene el conteo total de las conexiones excitatorias e inhibitorias que influyen en los vecindarios sinápticos correspondientes a cada neurona de salida en cada una de las simulaciones.

Luego de esto, se obtuvieron los porcentajes de conexiones excitatorias e inhibitorias de las cantidades obtenidas anteriormente. En la figura 4.6 se presenta un ejemplo de este archivo, se destaca en color azul los porcentajes de las conexiones involucradas con la neurona de salida que corresponde a la respuesta correcta, por ejemplo, para el caso de un individuo normal en el problema de dificultad para caminar la respuesta considerada como correcta es caminar normal.

En el problema de dificultad al caminar se pudo observar que en todas las simulaciones estos porcentajes rondan aproximadamente el 20% del total tanto para excitatorias como para inhibitorias.

En el caso del problema de dificultad con tareas de motricidad fina estos porcentajes rondan el 25% debido a que se tienen solo 4 neuronas de salida.

El archivo “Resumen.xlsx” es el que contiene la información del análisis del componente de memoria combinatoria, es decir, el conteo de conexiones excitatorias e inhibitorias, los porcentajes correspondientes, el aprendizaje promedio y la clasificación de cada una de las gráficas de aprendizaje.

En la figura 4.6 se muestra una pequeña parte de estos dos documentos.

Conteo de Conexiones Sinápticas										
Simulación	0-9999		10000-19999		20000-29999		30000-39999		40000-49999	
	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory
0	36035	3965	35955	4045	36039	3961	36022	3978	35949	4051
1	35926	4074	36001	3999	35958	4042	36057	3943	36058	3942
2	35965	4035	35955	4045	36140	3860	35965	4035	35975	4025
3	35993	4007	35962	4038	35974	4026	35987	4013	36084	3916
4	36028	3972	35963	4037	36024	3976	36056	3944	35929	4071
5	35962	4038	36020	3980	35968	4032	36026	3974	36034	3976

% Conteo de Conexiones Sinápticas										
Simulación	0-9999		10000-19999		20000-29999		30000-39999		40000-49999	
	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory
0	20.02	19.83	19.98	20.23	20.02	19.81	20.01	19.89	19.97	20.26
1	19.96	20.37	20.00	20.00	19.98	20.21	20.03	19.72	20.03	19.71
2	19.98	20.18	19.98	20.23	20.08	19.30	19.98	20.18	19.99	20.13
3	20.00	20.04	19.98	20.19	19.99	20.13	19.99	20.07	20.05	19.58
4	20.02	19.86	19.98	20.19	20.01	19.88	20.03	19.72	19.96	20.36
5	19.98	20.19	20.01	19.90	19.98	20.16	20.01	19.87	20.01	19.88

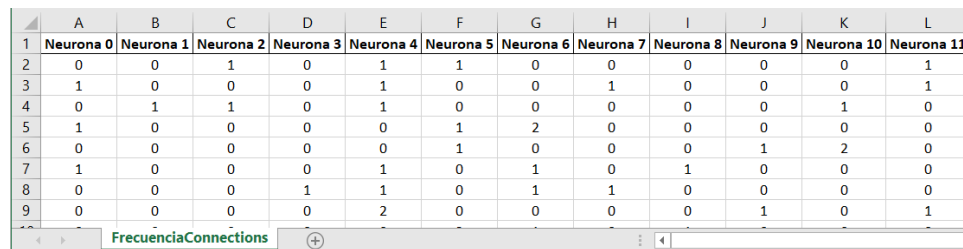
**Figura 4.6:** Parte del archivo del análisis de la memoria combinatoria. Las columnas en color azul hacen referencia a las conexiones involucradas con la neurona de salida correspondiente a la respuesta correcta.

Después de analizar los resultados anteriores se llega a la conclusión de que si cada simulación depende de un archivo correspondiente a las conexiones sinápticas y otro

a los pesos sinápticas de estas conexiones, y si en cada simulación estos archivos son distintos y la presentación de los objetos de aprendizaje se realiza en el mismo orden en cada simulación, es decir, la activación de las neuronas de entrada siempre es igual, entonces alguna relación debe existir entre estos dos archivos para que en unas simulaciones se den aprendizajes con comportamientos estables y en otras sólo se tengan fluctuaciones y por lo tanto no se aprende nada.

Para tratar de encontrar una relación entre estos archivos se obtuvieron las frecuencias de aparición de las conexiones y los pesos sinápticos en cada una de las neuronas de la capa oculta, es decir, de cada uno de los archivos Connections.xlsx, se calculó el número de veces que las 12 neuronas sensoriales de la capa de entrada realizan sinapsis con cada una de las neuronas de la capa oculta y en los archivos SynapticWeights.xlsx se cuentan el total de conexiones excitatorias e inhibitorias que se tienen en cada neurona de la capa oculta.

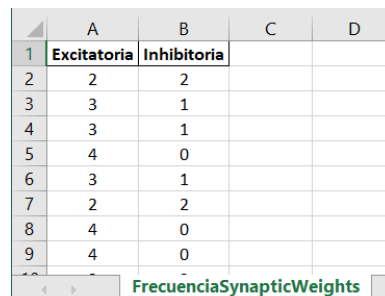
En la figura 4.7, se muestra un ejemplo de cómo quedó el cálculo de estas frecuencias para los archivos Connections.xlsx.



	A	B	C	D	E	F	G	H	I	J	K	L
1	Neurona 0	Neurona 1	Neurona 2	Neurona 3	Neurona 4	Neurona 5	Neurona 6	Neurona 7	Neurona 8	Neurona 9	Neurona 10	Neurona 11
2	0	0	1	0	1	1	0	0	0	0	0	1
3	1	0	0	0	1	0	0	1	0	0	0	1
4	0	1	1	0	1	0	0	0	0	0	1	0
5	1	0	0	0	0	1	2	0	0	0	0	0
6	0	0	0	0	0	1	0	0	0	1	2	0
7	1	0	0	0	1	0	1	0	1	0	0	0
8	0	0	0	1	1	0	1	1	0	0	0	0
9	0	0	0	0	2	0	0	0	0	1	0	1

**Figura 4.7:** Parte del archivo con las frecuencias obtenidas de los archivos Connections.xlsx.

En la figura 4.8, se muestra un ejemplo del archivo donde se tienen las frecuencias para los archivos SynapticWeights.xlsx.




	A	B	C	D
1	Excitatoria	Inhibitoria		
2	2	2		
3	3	1		
4	3	1		
5	4	0		
6	3	1		
7	2	2		
8	4	0		
9	4	0		

**Figura 4.8:** Parte del archivo con las frecuencias obtenidas de los archivos SynapticWeights.xlsx.

## 4. ANÁLISIS DE RESULTADOS

---

Poder encontrar una relación entre estas frecuencias visualmente sería muy complicado ya que se tiene un número muy grande de neuronas en la capa oculta y al graficarlas resulta complicado poder distinguir algún comportamiento que nos lleve a una conclusión. En la figura 4.9 se muestra un ejemplo de las gráficas correspondientes a estas frecuencias, se muestran solo las primeras 50 neuronas de la capa oculta debido a que tomando el total de neuronas no se puede apreciar nada en las gráficas.



**Figura 4.9:** Gráficas de las frecuencias de las conexiones y sus pesos sinápticos, es decir conexión excitatoria o inhibitoria.

Debido a la gran cantidad de datos que se tienen se decidió tomar únicamente los archivos de conexiones y de pesos sinápticos de las simulaciones donde se obtuvo el aprendizaje mayor y el menor con cada porcentaje de conexiones excitatorias(%) -inhibitorias(%) para los resultados del individuo sano y el que sufrió un paro cardio-respiratorio para tratar de encontrar una relación entre estos datos.

Por lo tanto, se decidió usar DBSCAN, un algoritmo de machine learning diseñado para detectar en forma automática “clusters”, es decir, agrupa elementos próximos entre sí de acuerdo a sus atributos, encuentra un número de grupos (clusters) comenzando por una estimación de la distribución de densidad de los clusters correspondientes.

El total de gráficas y archivos con extensión .xlsx se podrá encontrar en OneDrive debido a que la cantidad total de gráficas es muy elevado y los archivos .xlsx son muy largos por lo tanto es complicado poder mostrarlos por completo en este documento.

La liga para acceder a estos archivos es:

[https://comunidadunamx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25\\_comunidad\\_unam\\_mx/E17AYAqON690t8003gKra0kBsiaFQiPc1Y94Wg1vjrfQWA](https://comunidadunamx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25_comunidad_unam_mx/E17AYAqON690t8003gKra0kBsiaFQiPc1Y94Wg1vjrfQWA), podrás solicitar el acceso a *kkarinasanchez25@gmail.com*.

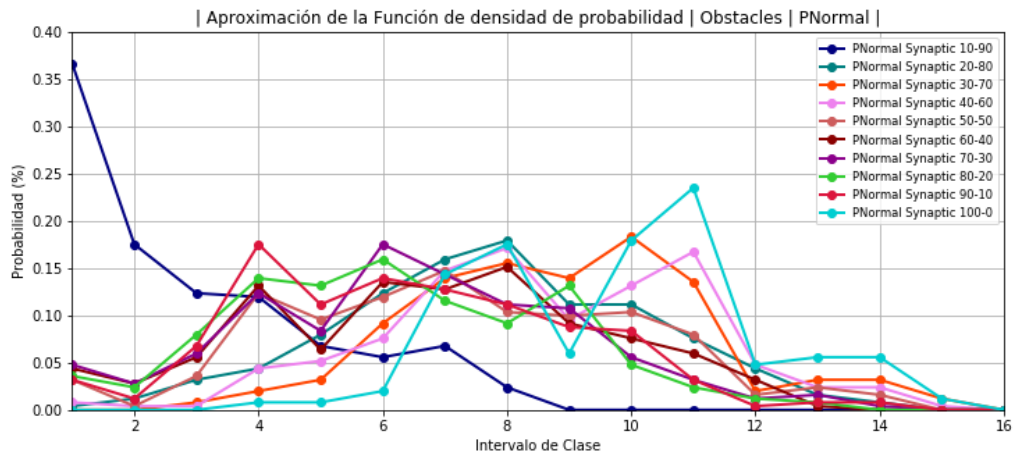
En el Apéndice A sección 8, se encuentra una descripción del contenido de cada carpeta y archivo.

Además en las secciones A.9 y A.10 se tiene todo mencionado anteriormente pero de manera individual, es decir para cada red neuronal en el problema de la dificultad al caminar para un individuo sano y uno con lesión cerebral respectivamente. De la misma manera se presentan los resultados de las redes neuronales del problema de dificultad con tareas de motricidad fina en las secciones A.11 y A.12.

#### 4.2.1. Problema: dificultad al caminar

Después de obtener cada uno de los histogramas de frecuencias de todos los puntos mencionados, se procedió a obtener una aproximación de la función de densidad de probabilidad de cada uno de ellos y realizar un breve análisis estadístico de estos resultados.

En la figura 4.10, se muestra la aproximación de la función de densidad de probabilidad correspondiente a los histogramas de frecuencias para el total de aprendizajes obtenidos en cada una de las simulaciones con cada diferente porcentaje en las conexiones sinápticas de un individuo sano, los valores de cada intervalo de clase están dados en la tabla 4.1.



**Figura 4.10:** Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano en el problema de dificultad al caminar.

Analizando las gráficas y tomando en cuenta primero los valores obtenidos en los intervalos que representan los aprendizajes que están por debajo del 50 %, es decir, del intervalo 1 al 8, notamos como la curva correspondiente a PNormal Synaptic 10-90 que tiene forma de J invertida, correspondiente a una función decreciente, nos indica que la mayoría de los aprendizajes se encuentran entre el 0 % y 6.25 %, esta curva es la que

#### 4. ANÁLISIS DE RESULTADOS

---

se encuentra por encima de todas las demás por lo menos en los intervalos 1 al 3.

A partir del intervalo 4 esto cambia, ya que la curva que se encuentra por encima de las demás es la de PNormal Synaptic 90-10 y que además es aquí donde esta curva presenta su punto máximo, porque después presenta un comportamiento decreciente, en el intervalo 5 tenemos que la curva que está por encima es la de PNormal Synaptic 80-20, sin embargo, no es su punto máximo. Para el intervalo 6 la curva que está por encima es la de PNormal Synaptic 70-30 y como en el caso anterior tampoco es su punto máximo, finalmente para los intervalos 7 y 8 la curva que tiene la mayor probabilidad es la de PNormal Synaptic 20-80, siendo el intervalo 8 su punto máximo ya que se observa una curva con tendencia a ser una función gaussiana concentrando la probabilidad mayor en los aprendizajes aproximadamente del 50 %.


Además, se distinguen dos grupos que conservan una tendencia igual. El primer grupo está formado por Synaptic 50-50, 60-40, 70-30, 80-20 y 90-10, en los que las probabilidades mayores se dan en los intervalos 4 y 6 es decir con aprendizajes menores al 37 %. El segundo grupo está formado por Synaptic 30-70, 40-60 y 100-0, donde las probabilidades mayores se dan en el intervalo 10, es decir, se tienen aprendizajes entre 56.25 % y 62.5 %.

Para todos los casos se observa como la curva comienza a decrecer a partir del intervalo 12, lo que indica que son muy pocos los casos en que se obtienen aprendizajes mayores al 68.75 %.

Al realizar el análisis de cada una de las redes neuronales se pudo observar que con conexiones sinápticas 80 % inhibitorias - 20 % inhibitorias y 90 % inhibitorias - 10 % inhibitorias se tienen resultados muy similares respecto a los aprendizajes y esto mismo se puede observar en la gráfica ya que las curvas son muy parecidas, sin embargo, en los intervalos con aprendizajes mayores (a partir del intervalo 12) la curva de PNormal Synaptic 80-20 esta un poco más por encima. A pesar de que tenemos curvas que están por encima de estas dos en los intervalos de interés, fijamos nuestra atención en las dos ya mencionadas por el hecho de que presentan un número de simulaciones con aprendizaje no válido menor a cualquier otra y en las dos se tiene la característica que llamamos la presencia de memoria, esto por el hecho de conservar el aprendizaje durante el mayor tiempo del aprendizaje.

Para un individuo sano la presencia de la característica de la memoria se dio a partir de la conexión 70 % excitatorias - 30 % inhibitorias.

Ahora en la figura 4.11 se presenta este mismo análisis pero para un individuo que sufrió una lesión cerebral.



**Figura 4.11:** Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio en el problema de dificultad al caminar.

Observamos que para PPCR Synaptic 10-90 se tiene una curva con forma de J invertida correspondiente a una función decreciente, es decir, sólo tenemos aprendizajes con valores muy bajos, para el caso Synaptic 20-80 se observa una curva suave sesgada a la derecha concentrando la probabilidad mayor en los aprendizajes aproximadamente entre 25 % y 31.25 %.

Además, también aquí se distinguen dos grupos que conservan una misma tendencia. El primer grupo está formado por Synaptic 50-50, 60-40, 70-30, 80-20 y 90-10 en los que las probabilidades mayores se dan en el intervalo 4, es decir, los aprendizajes entre 18.75 % y 25 %. El segundo grupo está formado por Synaptic 30-70, 40-60 y 100-0 donde las probabilidades mayores se dan en los intervalos 8 y 10, es decir, se tienen aprendizajes entre 43.74 % y 50 % y entre 56.25 % y 62.5 %.


Para todos los casos se observa como la curva comienza a decrecer a partir del intervalo 10, lo que indica que son muy pocos los casos en que se obtienen aprendizajes mayores al 62.5 %.

Al analizar cada una de las curvas podemos notar que las correspondientes a las conexiones sinápticas 30 % inhibitorias - 70 % inhibitorias y 40 % inhibitorias - 60 % inhibitorias se tienen resultados muy similares, ya que si fijamos nuestra atención en los aprendizajes mayores (a partir del intervalo 10) son las que se encuentran por encima de las demás descartando la de PPCR Synaptic 100-0, sin embargo, si ahora nos fijamos en el intervalo 11 la que se encuentra por encima es la Synaptic 40-60 lo que nos indica que es en la que se obtienen más aprendizajes superiores al 62.5 % y por ende se obtiene un número mayor de respuestas correctas.

#### 4. ANÁLISIS DE RESULTADOS

Para un individuo que sufrió una lesión cerebral la presencia de la característica de la memoria también se dio a partir de la conexión 70 % excitatorias - 30 % inhibitorias.

Por último, en la figura 4.12 se muestran las dos anteriores pero juntas, para poder visualizar las diferencias.



**Figura 4.12:** Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano y uno que sufrió un paro cardiorespiratorio en el problema de dificultad al caminar.

Observamos que las curvas correspondientes a una persona que sufrió un paro cardiorespiratorio tienden a estar más cargadas hacia los intervalos con aprendizajes menores, lo que corrobora las conclusiones que se realizaron de manera individual en cada red neuronal donde para todos los casos en las conexiones sinápticas de un individuo sano los aprendizajes fueron más altos.

Podemos notar como las curvas correspondientes tienen una misma tendencia, es decir, la curva de PPCR sigue la misma tendencia que su correspondiente curva de PNormal de acuerdo a cada uno de los porcentajes entre conexiones excitatorias-inhibitorias, sin embargo, en los intervalos donde se tienen los aprendizajes menores al 50 % las curvas de PPCR siempre están por encima de su respectiva curva de PNormal y donde esto se hace más evidente es en los intervalos del 1 al 4 que es donde se tiene la mayor acumulación.

Finalmente en la tabla 4.2 se tiene un resumen para el total de conexiones sinápticas distintas en el problema de la dificultad al caminar para un individuo sano y uno que sufrió un paro cardiorespiratorio, donde se incluyen el aprendizaje promedio total, los

valores correspondientes a la clasificación del comportamiento de aprendizaje y el total de simulaciones en las que se obtuvieron las 4 respuestas correctas, ya que el objetivo no solo es tener aprendizajes altos sino que se lograran aprender todas las respuestas correctas para que la actividad de caminar se pueda desempeñar de la mejor manera al presentarse distintos obstáculos.

Red Neuronal Artificial	Aprendizaje			Simulaciones	
	Promedio	NA	AV	ANV	con 4 Resp Correctas
	<b>Total</b>				
PNormal 10-90	14.39 %	191	54	6	0 (0)
PNormal 20-80	45.65 %	158	49	44	10 (36)
PNormal 30-70	52.38 %	77	96	78	25 (73)
PNormal 40-60	50.76 %	85	90	76	20 (72)
PNormal 50-50	41.99 %	91	86	74	17 (43)
PNormal 60-40	38.54 %	56	108	87	8 (68)
PNormal 70-30	37.04 %	37	111	103	14 (63)
PNormal 80-20	35.76 %	31	113	107	10 (74)
PNormal 90-10	36.76 %	18	113	120	15 (69)
PNormal 100-0	57.87 %	12	139	100	41 (121)
PPCR 10-90	7.76 %	227	24	0	0 (0)
PPCR 20-80	29.05 %	172	36	43	0 (3)
PPCR 30-70	40.56 %	111	79	61	5 (36)
PPCR 40-60	38.55 %	106	92	53	1 (40)
PPCR 50-50	27.76 %	142	62	47	2 (9)
PPCR 60-40	22.84 %	103	78	70	2 (10)
PPCR 70-30	20.47 %	83	98	70	1 (10)
PPCR 80-20	21.27 %	68	97	86	0 (15)
PPCR 90-10	19.58 %	65	113	72	0 (14)
PPCR 100-0	47.92 %	21	114	116	13 (99)

**Tabla 4.2:** Conteo total de clasificación del aprendizaje para dificultad para caminar.

Como se puede observar, en la última columna se tienen valores entre ( ), estos valores representan en total de simulaciones en las que se obtuvieron 3 respuestas correctas,

## 4. ANÁLISIS DE RESULTADOS

---

esto se debe a que para todas las redes neuronales se tienen muy pocas simulaciones con las 4 respuestas correctas y era más complicado poder sacar conclusiones acerca de cuáles fueron las que presentaron el mejor comportamiento, hablando tanto de aprendizaje promedio pero sobre todo del total de aciertos obtenidos.

Observando estos valores concluimos que los casos de las conexiones 100% excitatorias - 100% inhibitorias se excluyen debido a que biológicamente esto no sucede, por lo tanto los mejores resultados para PNormal fueron con 80% excitatorias - 20% inhibitorias y para PPCR fue 40% excitatorias - 60% inhibitorias, con lo que nuestras hipótesis se cumplen.

### 4.2.1.1. Análisis de Cj con DBSCAN

Como ya se mencionó, se realizó un análisis de Cj con el algoritmo DBSCAN. Para la implementación de este algoritmo se requieren dos parámetros:

1. **eps**: La distancia máxima entre dos muestras para que una se considere en la vecindad de la otra. Este no es un límite máximo en las distancias de puntos dentro de un grupo. Este es el parámetro DBSCAN más importante para elegir adecuadamente para su conjunto de datos y función de distancia.
2. **min\_samples**: El número de muestras en un vecindario para que un punto sea considerado como un punto central. Esto incluye el punto en sí.

Al aplicar el algoritmo obtenemos el número de clusters, el número de puntos de ruido, es decir los que quedan fuera de los clusters y además el coeficiente Silhouette, que proporciona una representación gráfica de lo bien que se ha clasificado cada objeto, Silhouette va de -1 a +1, donde un valor alto indica que el objeto está bien combinado con su propio cúmulo y mal combinado con los cúmulos vecinos. Si la mayoría de los objetos tienen un valor alto, entonces la configuración del cúmulo es apropiada. Si muchos puntos tienen un valor bajo o negativo, entonces la configuración de cúmulos puede tener demasiados o muy pocos cúmulos.

Por lo tanto, se generaron de manera aleatoria los valores para eps y min\_samples para encontrar la combinación donde el coeficiente Silhouette sea el valor más alto, la matriz de datos a la que se le aplicó DBSCAN fue el conjunto de frecuencias de conexiones con sus respectivos pesos sinápticos, es decir, se generó una matriz concatenando las frecuencias de las conexiones con las frecuencias de los pesos sinápticos.

En la tabla 4.3 se muestran los valores tanto de los parámetros de DBSCAN como de los resultados del número de clusters, los puntos de ruido y el valor del coeficiente Silhouette mayor, encontrado durante el experimento para las frecuencias de las conexiones y los pesos sinápticos de las simulaciones del aprendizaje mayor y menor para un individuo sano y uno que sufrió un paro cardiorespiratorio en el problema de dificultad al caminar.

Conexiones Exc( %)-Inh( %)	Aprendizaje Mayor	eps	min_samples	Número de Clusters	Puntos de Ruido	Coefficiente Silhouette	Aprendizaje Menor	eps	min_samples	Número de Clusters	Puntos de Ruido	Coefficiente Silhouette
PNormal												
10 %-90 %	45.75 %	0.34	2	3373	548	0.9828	0 %	0.153	2	3381	563	0.9823
20 %-80 %	84 %	0.887	2	4250	606	0.9798	6.125 %	0.174	2	4230	656	0.9781
30 %-70 %	91.875 %	0.334	2	4914	659	0.9773	17 %	0.067	2	4949	620	0.9786
40 %-60 %	89.75 %	0.256	2	5387	698	0.9754	0 %	0.718	2	5346	774	0.9727
50 %-50 %	86.25 %	0.705	2	5578	729	0.9739	0 %	0.49	2	5575	693	0.9752
60 %-40 %	76.875 %	0.337	2	5401	694	0.9755	0 %	0.932	2	5365	724	0.9745
70 %-30 %	82.75 %	0.26	2	4926	655	0.9774	0 %	0.865	2	4940	629	0.9783
80 %-20 %	81.125 %	0.489	2	4267	604	0.9799	0 %	0.958	2	4231	624	0.9793
90 %-10 %	82.25 %	0.237	2	3369	577	0.9818	0 %	0.537	2	3325	612	0.9808
100 %-0 %	92.625 %	0.035	2	1361	3	.9998	24.875 %	0.285	2	1363	1	0.9999
PPCR												
10 %-90 %	45.125 %	0.015	2	3399	532	0.9832	0 %	0.699	2	3371	566	0.9822
20 %-80 %	72.875 %	0.19	2	4231	636	0.9788	1 %	0.042	2	4229	638	0.9787
30 %-70 %	84.875 %	0.043	2	4916	627	0.9783	5 %	0.032	2	4907	659	0.9774
40 %-60 %	73.5 %	0.037	2	5371	685	0.9758	0.625 %	0.702	2	5364	739	0.9740
50 %-50 %	75.5 %	0.555	2	5595	757	0.9730	0 %	0.103	2	5591	753	0.9731
60 %-40 %	75.25 %	0.286	2	5361	713	0.9749	0 %	0.977	2	5356	752	0.9735
70 %-30 %	76.75 %	0.3	2	4949	663	0.9772	0 %	0.504	2	4951	604	0.9792
80 %-20 %	64.375 %	0.121	2	4243	663	0.9780	0 %	0.553	2	4244	649	0.9783
90 %-10 %	63 %	0.447	2	3395	578	0.9818	0 %	0.715	2	3376	556	0.9824
100 %-0 %	77.25 %	0.02	2	1359	2	0.9999	1.125 %	0.465	2	1360	5	0.9998


**Tabla 4.3:** Resultados DBSCAN para individuo sano y uno que sufrió un paro cardiorrespiratorio en dificultad al caminar.

## 4. ANÁLISIS DE RESULTADOS

Al analizar los resultados nos percatamos que el valor más alto del coeficiente Silhouette se dan cuando el valor de `ms_samples` es 2 y `eps` se encuentra en el intervalo (0,1]. Teniendo todos los casos con esta característica podemos observar que el patrón más evidente es que para la mayoría de las simulaciones, donde se obtuvo el aprendizaje mayor, el número de puntos de ruido es menor que en las simulaciones donde se obtuvo el aprendizaje menor, lo que nos indica que existe una mejor agrupación de los datos y podría explicarse que se tengan mejores resultados en el aprendizaje.

### 4.2.2. Problema: dificultad con tareas de motricidad fina

Para el problema de dificultad con tareas de motricidad fina se presenta en la figura 4.13 la aproximación de la función de densidad de probabilidad correspondiente a los histogramas de frecuencias para el total de aprendizajes obtenidos en cada una de las simulaciones con cada diferente porcentaje en las conexiones sinápticas de un individuo sano.



**Figura 4.13:** Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano en el problema de dificultad con tareas de motricidad fina.

Observamos que para PNormal Synaptic 10-90 se tiene una curva correspondiente a una función decreciente, es decir, solo tenemos aprendizajes con valores muy bajos ya que para estas conexiones sinápticas no se logró aprender nada y todos los aprendizajes fueron nulos, para el caso Synaptic 20-80 se observa una curva sesgada a la derecha donde la probabilidad mayor se da para los aprendizajes entre 37.5 % y 43.75 %, a di-

ferencia del caso Synaptic 30-70 que presenta una curva sesgada hacia la izquierda, es decir, hacia los aprendizajes mayores.

Podemos notar que existen dos grupos en los que se observa claramente que las curvas siguen la misma tendencia. El primer grupo está formado por Synaptic 40-60, 50-50, 60-40 y 100-0 en los que las probabilidades mayores se dan en el intervalo 15 es decir con aprendizajes entre el 87.5 % y 93.75 %. El segundo grupo está formado por Synaptic 70-30, 80-20 y 90-10 donde las probabilidades mayores se dan en el intervalo 14, es decir, se tienen aprendizajes entre 81.25 % y 87.5 % un poco menores a los del grupo anterior.


Para todos los casos a partir del Synaptic 40-60 se observa como la curva comienza a crecer a partir del intervalo 12, lo que indica que la mayoría obtuvo aprendizajes mayores al 68.75 %.

Como se explicó en las conclusiones de cada una las simulaciones con conexiones sinápticas 80 % inhibitorias - 20 % inhibitorias y 90 % inhibitorias - 10 % inhibitorias se tienen resultados muy similares respecto a los aprendizajes, esto se puede observar en la gráfica ya que las curvas son muy parecidas, sin embargo, en el intervalo donde se presenta la mayor probabilidad (intervalo 14) la curva de PNormal Synaptic 80-20 esta por encima. A pesar de que tenemos curvas que están por encima de estas dos en los intervalos de interés, fijamos nuestra atención en las dos ya mencionadas por el hecho de que presentan un número de simulaciones con aprendizaje no válido menor a cualquier otra y que además tienen la característica de que se observa la presencia de la memoria a largo plazo al conservar el aprendizaje durante el mayor tiempo del aprendizaje.

Esta característica se comenzó a dar a partir de la conexión 60 % excitatorias - 40 % inhibitorias.

Para un individuo que sufrió una lesión cerebral se presentan la aproximación de la función de densidad de probabilidad en la figura 4.14.

#### 4. ANÁLISIS DE RESULTADOS



**Figura 4.14:** Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio en el problema de dificultad con tareas de motricidad fina.


Observamos que para PPCR Synaptic 10-90 se tiene una curva correspondiente a una función decreciente, es decir, solo tenemos aprendizajes con valores muy bajos ya que para estas conexiones sinápticas no se logró aprender nada y todos los aprendizajes fueron nulos. Para el caso Synaptic 20-80 se observa una curva en forma de J invertida donde la probabilidad mayor se da para los aprendizajes más bajos que están entre 0% y 6.25% a diferencia del caso Synaptic 30-70 que presenta una curva que parece ser una gaussiana donde la mayor probabilidad es para los aprendizajes que están entre 43.75% al 50%.

Notamos que los demás casos presentan un comportamiento similar a funciones bimodales, donde los puntos máximos de probabilidad se dan en los intervalos 11 y 15 es decir con aprendizajes entre el 62.5% y 68.75% y entre 87.5% y 93.75%.

Si fijamos nuestra atención en las curvas en las que se obtuvo el número menor de simulaciones con comportamientos no válidos, que son PPCR Synaptic 90-10, 80-20 y 50-50 observamos que las curvas son muy parecidas, sin embargo, al observar el comportamiento en el intervalo 15 que es donde todos los casos comienzan a decrecer, nos damos cuenta que la curva de PPCR Synaptic 50-50 está por encima de las otras y además fue en la que se obtuvo el mayor número de simulaciones con 4 respuestas correctas.

En este caso la presencia de la memoria se dio a partir de la conexión 50% excitatorias - 50% inhibitorias.

En la figura 4.15 se muestran las dos anteriores juntas.



**Figura 4.15:** Aproximación de la función de densidad de probabilidad para todos los distintos porcentajes en las conexiones sinápticas de un individuo sano y uno que sufrió un paro cardiorrespiratorio en el problema de dificultad al caminar.

Observamos que las curvas tanto para una persona sana como para una que sufrió un paro cardiorrespiratorio tienden a estar más cargadas hacia los intervalos con aprendizajes mayores, sin embargo, las de la persona sana están por encima.

Comparando estos resultados con los del problema en la dificultad al caminar observamos que los resultados fueron similares de modo que para una persona sana los resultados fueron mayores que los de la persona que sufrió un paro cardiorrespiratorio, en los dos se observó la presencia de la memoria a largo plazo aunque para el problema de la dificultad con tareas de motricidad fina no se tuvo la coincidencia que se presentará con los mismos porcentajes en las conexiones sinápticas.

En la tabla 4.4 se tiene un resumen para el total de conexiones sinápticas distintas en el problema de la dificultad con tareas de motricidad fina para un individuo sano y uno que sufrió un paro cardiorrespiratorio donde se incluyen el aprendizaje promedio

#### 4. ANÁLISIS DE RESULTADOS

---

total, los valores correspondientes a la clasificación del comportamiento de aprendizaje y el total de simulaciones en las que se obtuvieron las 4 respuestas correctas, ya que el objetivo no solo es tener aprendizajes altos sino que se lograran aprender todas las respuestas correctas para que la actividad de sujetar objetos de dimensión media-pequeña se pueda desempeñar de la mejor manera al presentarse distintos objetos.

Red Neuronal Artificial	Aprendizaje			Simulaciones	
	Promedio	NA	AV	ANV	con 4 Resp Correctas
	<b>Total</b>				
PNormal 10-90	0%	251	0	0	0
PNormal 20-80	31.07%	171	61	19	0
PNormal 30-70	68.59%	171	51	29	49
PNormal 40-60	82.8%	53	134	64	179
PNormal 50-50	86.94%	6	155	90	243
PNormal 60-40	86.24%	10	156	85	238
PNormal 70-30	83.47%	10	160	81	219
PNormal 80-20	83.34%	2	154	95	237
PNormal 90-10	82.66%	0	164	87	223
PNormal 100-0	87.57%	0	133	118	251
PPCR 10-90	0%	251	0	0	0
PPCR 20-80	15.23%	208	42	1	0
PPCR 30-70	47.56%	187	37	27	9
PPCR 40-60	68%	140	65	46	46
PPCR 50-50	79.5%	15	144	92	144
PPCR 60-40	75.07%	37	117	97	120
PPCR 70-30	74.1%	11	112	128	110
PPCR 80-20	75.68%	5	125	121	123
PPCR 90-10	74.71%	1	127	123	127
PPCR 100-0	81.12%	0	155	96	156

**Tabla 4.4:** Conteo total de clasificación del aprendizaje para dificultad con tareas de motricidad fina.

Para este caso no fue necesario agregar el total de simulaciones donde se obtuvieron

3 respuestas correctas debido a que los resultados para los 4 aciertos fue satisfactoria.

Realizando el mismo análisis que en el problema anterior, observamos que los mejores resultados para PNormal se obtuvieron con las conexiones 80 % excitatorias - 20 % inhibitorias y para PPCR con 50 % excitatorias - 50 % inhibitorias.

Por lo tanto, con estos resultados también se cumplen nuestras hipótesis.

#### **4.2.2.1. Análisis de Cj con DBSCAN**

Para este problema también se realizó el análisis de Cj con el algoritmo DBSCAN.

En la tabla 4.5 se muestran los valores tanto de los parámetros de DBSCAN como de los resultados del número de clusters, los puntos de ruido y el valor del coeficiente Silhouette mayor encontrado durante el experimento para las frecuencias de las conexiones y los pesos sinápticos para las simulaciones del aprendizaje mayor y menor para un individuo sano y uno que sufrió un paro cardiorespiratorio en el problema de dificultad con tareas de motricidad fina, para este caso se omiten las conexiones 10 % excitatorias - 90 % inhibitorias ya que en ninguna simulación se logró aprender absolutamente nada.

Al igual que en el problema anterior, nos percatamos que el valor más alto del coeficiente Silhouette se dan cuando el valor de `ms_samples` es 2 y `eps` se encuentra en el intervalo  $(0,1]$ , teniendo todos los casos con esta característica podemos observar que el patrón más evidente es que para la mayoría de las simulaciones donde se obtuvo el aprendizaje mayor el número de puntos de ruido es menor que en las simulaciones donde se obtuvo el aprendizaje menor, lo que nos indica que existe una mejor agrupación de los datos y podría explicarse que se tengan mejores resultados en el aprendizaje.

Conexiones Exc( %)-Inh( %)	Aprendizaje Mayor	eps	min_samples	Número de Clusters	Puntos de Ruido	Coefficiente Silhouette	Aprendizaje Menor	eps	min_samples	Número de Clusters	Puntos de Ruido	Coefficiente Silhouette
PNormal												
20%-80%	48.125%	0.918	2	4030	702	0.9707	0.75%	0.107	2	4050	680	0.9716
30%-70%	92.875%	0.009	2	4678	727	0.9687	25.75%	0.491	2	4700	736	0.9684
40%-60%	97.625%	0.511	2	5091	861	0.9620	57.25%	0.553	2	5127	795	0.9650
50%-50%	94%	0.385	2	5267	889	0.9604	62%	0.513	2	5235	899	0.9600
60%-40%	94.5%	0.971	2	5077	847	0.9627	62.125%	0.263	2	5085	829	0.9635
70%-30%	92.875%	0.792	2	4723	689	0.9703	55.875%	0.061	2	4725	714	0.9693
80%-20%	93.25%	0.798	2	4050	674	0.9719	62.125%	0.914	2	4040	676	0.9719
90%-10%	92.75%	0.817	2	3210	558	0.9781	47.5%	0.008	2	3189	588	0.9770
100%-0%	94%	0.043	2	1358	3	0.9998	77.5%	0.026	2	1362	3	0.9998
PPCR												
20%-80%	47.625%	0.515	2	4071	687	0.9714	0%	0.266	2	4072	690	0.9712
30%-70%	93.5%	0.017	2	4701	711	0.9694	2.5%	0.606	2	4723	738	0.9683
40%-60%	95.125%	0.913	2	5108	798	0.9649	19.75%	0.925	2	5080	812	0.9643
50%-50%	95.5%	0.616	2	5248	898	0.9601	40.375%	0.638	2	5226	949	0.9578
60%-40%	95.25%	0.054	2	5139	806	0.9645	42.375%	0.115	2	5098	832	0.9633
70%-30%	95.5%	0.608	2	4725	722	.9690	40.5%	0.744	2	7422	716	0.9693
80%-20%	95%	0.979	2	4061	672	0.9720	39.625%	0.837	2	4054	671	0.9720
90%-10%	95.25%	0.264	2	3184	578	0.9773	40.125%	0.021	2	3197	613	0.9760
100%-0%	95.25%	0.731	2	1360	3	0.9998	62.125%	0.364	2	1360	4	0.9998

**Tabla 4.5:** Resultados DBSCAN para individuo sano y uno que sufrió un paro cardiorespiratorio en dificultad con tareas de motricidad fina.

## 4.3. Resumen de entrenamiento de BP con Diferencias Temporales

### Características generales de las redes neuronales

La topología de la red neuronal totalmente conectada consta de 3 capas, una capa de entrada, una capa oculta y una capa de salida donde:

- En la capa de entrada se tienen 12 neuronas con estado binario (0 se refiere a que se encuentra inactiva, 1 indica que la neurona se encuentra activa), cada una de las neuronas representa una de las características del obstáculo u objeto ya definidas en el capítulo 3, sección 3.2.1.1, tablas 3.1, 3.5 y sección 3.2.2.1, tablas 3.9, 3.13.
- En la capa de salida se tiene 1 neurona, al ser back-propagation un modelo usado para la clasificación, de acuerdo a las características dadas en la capa de entrada se etiquetan las clases a las que corresponde el obstáculo.
- En la capa oculta se tienen 10,000 neuronas. Esta asignación se hace del mismo modo que en modelo RMCS (M. Rvachev, 2013), es decir, 10.000 por neurona de salida.

### Resumen de etapa de entrenamiento y prueba

Para poder realizar el entrenamiento de las redes neuronales tanto para un individuo normal como para uno que sufrió un paro cardiorrespiratorio primero obtuvimos los archivos `ObstaclesTraining.xlsx`, `ObstaclesTest.xlsx` y `ObjectsTraining.xlsx`, `ObjectsTest.xlsx` respectivamente para cada problema, donde:

- `ObstaclesTraining.xlsx` y `ObjectsTraining.xlsx` contienen los obstáculos u objetos de entrenamiento y la salida deseada para cada uno de ellos.
- `ObstaclesTest.xlsx` y `ObjectsTest.xlsx` contienen los obstáculos u objetos de prueba y su salida deseada calculada del mismo modo que el archivo anterior.

La salida deseada para estos archivos es calcula con la ecuación 3.27 donde se tomaron dos valores de  $\alpha$ , que representa la tasa de aprendizaje, generados de manera aleatoria ( $\alpha = 0.85535$  y  $\alpha = 0.005$ ) y la asignación de recompensas de las tablas 3.2 y 3.10.

El entrenamiento se lleva a cabo por épocas. Al inicio del entrenamiento, se generan de manera aleatoria los pesos sinápticos y pesos de vecindario de sinapsis.

Para cada época:

## 4. ANÁLISIS DE RESULTADOS

---

1. Se selecciona un vector de entrada desde el conjunto de entrenamiento (ObstaclesTraining.xlsx u ObjectsTraining.xlsx).
2. Se aplica esa entrada a la red y se calcula la salida.
3. Se calcula el error entre la salida calculada (predicción) y la salida deseada que se encuentra en el mismo archivo de donde se seleccionó el vector de entrada.
4. Se calcula el componente de memoria combinatoria  $C_j$ , estos resultados se guardan en archivos con extensión .xlsx que se generan durante el entrenamiento.
5. Ajustar los pesos sinápticos y de vecindario de sinapsis con el algoritmo de diferencias temporales.

Al terminar la etapa de entrenamiento, procedemos a la etapa de prueba donde, para el total de objetos de prueba:

- Seleccionamos el vector de entrada desde el conjunto de prueba (ObstaclesTest.xlsx u ObjectsTest.xlsx).
- Se aplica esa entrada a la red y se calcula la salida.
- Se gráfica la predicción.

El total de archivos con extensión .xlsx se podrán encontrar en OneDrive debido a que los archivos son largos por lo tanto es complicado poder mostrarlos por completo en este documento.

La liga para acceder a estos archivos es:

[https://comunidadunammx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25\\_comunidad\\_unam\\_mx/E17AYAq0N690t8003gKra0kBOLn8yopMYvwoWRGzGeToZw?e=e19oTm](https://comunidadunammx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25_comunidad_unam_mx/E17AYAq0N690t8003gKra0kBOLn8yopMYvwoWRGzGeToZw?e=e19oTm), podrás solicitar el acceso a *kkarinasanchez25@gmail.com*.

En el Apéndice A sección A.8 se encuentra una descripción del contenido de cada carpeta y archivo.

### 4.4. Resultados de BP con diferencias temporales

Como ya se mencionó anteriormente, para el entrenamiento de las redes neuronales con este modelo se utilizaron dos distintos valores para la variable  $\alpha$  que representa la tasa de aprendizaje y es necesaria para los cálculos del algoritmo de diferencias temporales durante el entrenamiento de la red neuronal y también en el cálculo de la salida deseada.

Los resultados obtenidos fueron distintos para cada uno de los valores de  $\alpha$ . Con el valor mayor se tuvieron dificultades durante el entrenamiento ya que nos percatamos

que el error se quedaba ciclado y en consecuencia se obtenían muy malas predicciones. Para solucionar este problema tuvo que ser modificada la topología de la red, disminuyendo las neuronas de la capa oculta a sólo 100.

Por lo tanto, podemos concluir que el modelo resultó eficiente tomando en cuenta que en todos los casos logró disminuir el error a 0 y además en una cantidad de épocas relativamente pequeña, obteniendo así predicciones exactas.

Sin embargo, el propósito de este trabajo no sólo era encontrar modelos perfectos sino encontrar en ellos la cantidad de conexiones que fueron necesarias para poder lograr esos resultados, lo que realmente estaríamos relacionando con las conexiones sinápticas de un cerebro humano. Al analizar estos resultados nos percatamos de que en los dos problemas abordados, el total de conexiones inhibitorias fue mayor para un individuo con lesión cerebral en comparación de las del individuo sano. Por lo tanto nuestras hipótesis planteadas al inicio se cumplen.

Ahora, como se ha venido mencionando durante todo el trabajo las simulaciones que se realizaron fueron sólo una aproximación a las conexiones del cerebro humano real, visto de este modo nuestros resultados son aceptables. Sin embargo, las deficiencias encontradas en el entrenamiento entre un valor u otro de la variable  $\alpha$  causaron un cambio en la topología de la red neuronal que nos deja aún más alejada de las conexiones neuronales del cerebro.

A continuación se presentan los detalles de los resultados de cada una de las redes neuronales, incluyendo información de su topología, épocas necesarias durante el entrenamiento y conexiones excitatorias e inhibitorias registradas en el componente de memoria combinatoria Cj.

Finalmente, en el Apéndice A, sección A.13 y A.14 se encuentran detalladamente los resultados para cada una de las redes neuronales.

#### 4.4.1. Problema: dificultad al caminar

En las tablas 4.6 y 4.7 se presentan los resultados para PNormal y PPCR tomando  $\alpha = 0.005$  y  $\alpha = 0.85535$  respectivamente para el problema de dificultad al caminar.

Se muestran el total de neuronas de la capa oculta, total de épocas, error inicial y final, total de conexiones y finalmente el porcentaje de conexiones excitatorias e inhibitorias con las que concluyó el entrenamiento.

En las dos tablas se tiene el mismo número en el total de conexiones respectivamente a los dos distintos valores de  $\alpha$ , sin embargo para un individuo con lesión cerebral es mayor el número de conexiones inhibitorias.

#### 4. ANÁLISIS DE RESULTADOS

---

Resultados con $\alpha = 0.005$							
Caso	Neuronas en capa oculta	Épocas totales	Error inicial	Error final	Total de conexiones	% Conexiones excitatorias	% Conexiones inhibitorias
PNormal	10,000	85	$1.03e^{08}$	0	40,000	11.625 %	88.375 %
PPCR	10,000	115	$1.07e^{08}$	0	40,000	10.745 %	89.255 %

**Tabla 4.6:** Resultados de BP con diferencias temporales para dificultad al caminar, tomando  $\alpha = 0.005$ .

Resultados con $\alpha = 0.85535$							
Caso	Neuronas en capa oculta	Épocas totales	Error inicial	Error final	Total de conexiones	% Conexiones excitatorias	% Conexiones inhibitorias
PNormal	100	49	8249.77	0	400	16.75 %	83.25 %
PPCR	100	61	7559.36	0	400	10.25 %	89.75 %

**Tabla 4.7:** Resultados de BP con diferencias temporales para dificultad al caminar, tomando  $\alpha = 0.85535$ .

#### 4.4.2. Problema: dificultad con tareas de motricidad fina

Para el problema de la dificultad con tareas de motricidad fina se presentan los resultados de la misma manera que el problema anterior. En las tablas 4.8 y 4.9 se presentan los resultados para los dos distintos valores de  $\alpha$ .

Al igual que en el anterior el total de conexiones inhibitorias es mayor para un individuo con lesión cerebral.

Resultados con $\alpha = 0.005$							
Caso	Neuronas en capa oculta	Épocas totales	Error inicial	Error final	Total de conexiones	% Conexiones excitatorias	% Conexiones inhibitorias
PNormal	10,000	115	65,169,428	0	49,241	0.24 %	99.76 %
PPCR	10,000	101	34,242,792	0	50,000	1.216 %	98.784 %

**Tabla 4.8:** Resultados de BP con diferencias temporales para dificultad con tareas de motricidad fina, tomando  $\alpha = 0.005$ .

Resultados con $\alpha = 0.85535$							
Caso	Neuronas en capa oculta	Épocas totales	Error inicial	Error final	Total de conexiones	% Conexiones excitatorias	% Conexiones inhibitorias
PNormal	100	62	13,986.03	0	500	1.4%	98.6%
PPCR	100	61	15,716.76	0	500	0.8%	99.2%

**Tabla 4.9:** Resultados de BP con diferencias temporales para dificultad con tareas de motricidad fina, tomando  $\alpha = 0.85535$ .

## 4.5. Interpretación de resultados

Después de realizar una presentación exhaustiva de los resultados numéricos (que se encuentra en el Apéndice A) se explicará ahora de manera sencilla todo el proceso para llegar a la solución de nuestro problema y la interpretación de estos resultados para poder verlos desde el punto biológico como es analizado en el capítulo de conclusiones.

El objetivo de la tesis es simular la conexión neuronal que se requiere para poder realizar actividades de la vida diaria, en este caso los problemas abordados son la dificultad al caminar y con tareas de motricidad fina, esta simulación es una pequeña aproximación.

Para simular estas conexiones neuronales usamos redes neuronales artificiales y al tratarse de un problema de toma de decisiones secuenciales es que se decide usar el aprendizaje por refuerzo ya que es el aprendizaje más apegado a la psicología conductista de los humanos, de este modo se agrega un componente de memoria combinatoria (Cj) a la red neuronal artificial donde se tiene el registro del total de conexiones excitatorias e inhibitorias que fueron necesarias para que el individuo pudiera realizar cada una de las actividades de la manera correcta.

Parte del objetivo es poder comparar estas conexiones realizadas entre un individuo sano y uno que sufrió un paro cardiorespiratorio ya que después de la lesión cerebral esta persona queda con secuelas serias que lo obligan a realizar estas actividades con limitaciones en su desempeño.

Queremos observar cómo se comportan estas conexiones cuando el individuo realiza estas actividades donde la finalidad es presentarle distintos objetos u obstáculos y él debe elegir la acción correcta de acuerdo a sus capacidades, es decir el individuo sano deberá realizar las actividades sin ninguna complicación y el individuo que sufrió una lesión cerebral realizará estas actividades de acuerdo a sus limitaciones.

#### 4. ANÁLISIS DE RESULTADOS

---

El funcionamiento en la etapa de aprendizaje del modelo RMCS (M. Rvachev, 2013) se resume a activar y desactivar cada una de las neuronas, en otras palabras se hacen o eliminan conexiones neuronales de acuerdo a las recompensas obtenidas al elegir una acción, este proceso es llevado a cabo por simulaciones, donde en cada simulación se genera una conexión neuronal inicial de manera aleatoria. En cada simulación son presentados objetos u obstáculos donde el objetivo es que aprenda a elegir la acción correcta de acuerdo al objeto u obstáculo presentado, luego en la etapa de prueba es registrado este aprendizaje a modo de cantidad de aciertos y errores cometidos al presentarle nuevos objetos u obstáculos. Todos los cambios en las conexiones son registrados en Cj.

Por lo que el punto más importante de los resultados arrojados son el comportamiento de Cj y el registro de aciertos y errores en la etapa de prueba ya que en los casos en que se obtengan 0 errores nos indica que se logró obtener la conexión neuronal con la que todas las actividades podrán ser desempeñadas de acuerdo al comportamiento de cada uno de los individuos (sano y con lesión cerebral).

Por lo tanto el objetivo de esta tesis, además de reproducir las conexiones neuronales y tratar de encontrar la conexión que permite a un individuo ya sea sano o con lesión cerebral realizar de la mejor manera las actividades motoras tratadas en este trabajo, es analizar el comportamiento del componente Cj, el cual fue parcialmente hecho ya que la etapa a seguir es la reproducción de escenarios para trabajar con secuencias de datos dependientes, generar las conexiones sinápticas iniciales usando distintas distribuciones de probabilidad y experimentar con distintos estados iniciales para las neuronas de la capa de entrada. Queremos entender el comportamiento de Cj que subyace a las acciones de una persona normal y otra con afectaciones en neuronas motoras con la finalidad de recrear comportamientos similares pero diferentes con base en el comportamiento de Cj.

Después de obtener los resultados de las 251 simulaciones, obtuvimos las gráficas de los aciertos y errores de cada una de ellas donde se puede observar cómo los aciertos aumentan conforme el tiempo de aprendizaje avanza, en algunos casos no se obtiene ningún acierto o estos varían es decir aprende y más adelante ya no reconoce el objeto.

En cada simulación para la etapa de entrenamiento se hacen 200 presentaciones de los objetos u obstáculos, por lo tanto se espera que al finalizar esas 200 presentaciones el total de aciertos sea el mayor posible, es claro que esto no se verá reflejado al inicio del aprendizaje debido a que comienza buscando las conexiones necesarias con las que logran las mejores recompensas y por ende logra aprender, de este modo tomamos como referencia las últimas 25 presentaciones ya que es donde podremos observar si finalizo el aprendizaje con un conocimiento claro de los objetos u obstáculos o simplemente no logro aprender nada.

Para el caso del modelo BP con diferencias temporales a pesar de que back-propagation

es muy conocido en aprendizaje supervisado, el algoritmo de diferencias temporales que estamos usando pertenece al aprendizaje por refuerzo, por lo tanto a pesar de que a primera vista se esté tratando el problema como un problema de clasificación, los datos son tomados de igual manera que en el modelo RMCS (M. Rvachev, 2013), sin embargo es importante mencionar que es posible obtener una gran cantidad de datos realizando simulaciones computacionales de los distintos escenarios, pero en este caso estaríamos hablando de eventos dependientes, una acción (decisión) dependería de la anterior. Para este trabajo solo se trabajaron con eventos independientes, sin embargo para trabajo futuro se pretende implementar esos escenarios para trabajar el mismo problema pero con cadenas de Markov y poder analizar si existen grandes cambios en los resultados.

Hasta la fecha no se conoce un estudio médico donde se nos indique cómo están distribuidas las conexiones sinápticas de nuestro cerebro, sin embargo es muy sabido que cuando se tiene una lesión cerebral estas conexiones se ven afectadas perdiéndose gran parte de ellas. Sin embargo, al realizar un análisis del componente Cj podemos encontrar alguna coincidencia entre las personas que presenten limitaciones al realizar estas actividades y entre las personas sanas y es de este modo es que se pudiera validar con individuos reales nuestros modelos.

Analizando el artículo base de este trabajo de donde tomamos el modelo RMCS (M. Rvachev, 2013) y que es donde éste es propuesto, se realiza la validación del componente Cj relacionándolo con un mecanismo similar al de un músculo, ellos proponen un ejemplo del funcionamiento completo del modelo mediante el problema de las manzanas y piedras, donde un individuo debe aprender a reconocer entre una manzana y una roca para comérsela o lanzarla, la validación no se realiza con sujetos reales. Este problema también fue añadido a esta tesis en el capítulo de validación del modelo para tener al menos la misma validación que los autores de la mencionada referencia en esta tesis.

Para este trabajo se comenzó con un análisis del componente Cj de manera gráfica, sin embargo, no fue posible observar de manera clara algún comportamiento debido al gran número de neuronas en la capa oculta, es por esto que fue usando el algoritmo DBSCAN como un primer acercamiento, sin embargo se tiene planeado a futuro poder realizar un análisis más completo de los resultados en Cj.

Debido a que este tipo de comparaciones aún no fueron realizadas en este trabajo, se mencionan en las conclusiones únicamente los porcentajes de neuronas excitatorias-inhibitorias con las que para este caso en particular (tomando a mi padre como el sujeto con lesión cerebral) se obtuvieron los mejores comportamientos, es decir donde se obtuvieron el mayor número de simulaciones con aprendizajes en los que el total de aciertos fuera el mayor.

El análisis estadístico que se realizó únicamente son aproximaciones ya que en

#### 4. ANÁLISIS DE RESULTADOS

---

ningún caso se obtuvo la función de densidad de probabilidad, sin embargo fue de gran utilidad ya que nos sirven para corroborar los resultados anteriores ya mencionados acerca de los aciertos obtenidos en cada simulación y gracias a esto podemos obtener las conclusiones de cuáles fueron las conexiones sinápticas con las que el individuo sano y el que sufrió una lesión cerebral realiza las actividades de la mejor manera de acuerdo a cada una de sus condiciones.

Para el modelo BP con diferencias temporales el análisis es más sencillo ya que el entrenamiento de la red neuronal se lleva a cabo como en cualquier otro problema de aprendizaje, sin embargo ya se comentó que el algoritmo de aprendizaje pertenece al aprendizaje por refuerzo.

Para cumplir con el propósito de este trabajo se añadió también a esta red el componente de memoria combinatoria Cj donde llevamos el registro de las conexiones neuronales excitatorias e inhibitorias, pero en este caso el registro se lleva de acuerdo a qué tan acertadas sean las predicciones obtenidas en la red neuronal, que corresponden a las acciones correctas que debe elegir el individuo. Por esta razón es que en este modelo no fue necesario realizar ningún otro tipo de análisis, porque en los resultados de Cj se tiene la información que buscamos.

Habiendo entendido esta explicación de cómo fueron interpretados los resultados obtenidos en cada uno de los modelos de aprendizaje, se presentan las conclusiones tanto particulares como la general en el siguiente capítulo.

---

## Capítulo 5

# Conclusiones

---

### Conclusiones Particulares:

El objetivo de este trabajo era simular de manera aproximada las conexiones neuronales de un individuo sano y uno que sufrió un paro cardiorespiratorio con las que pudiera desempeñar la actividad de caminar y de sujetar de la mejor manera posible de acuerdo a la condición de cada uno, es decir el individuo sano tendría que poder caminar de manera normal ante cualquier obstáculo y sujetar cualquier objeto sin mayor dificultad, mientras que el individuo que sufrió un paro cardiorespiratorio desempeña estas actividades con ciertas limitaciones como lo son las mioclonías, se propusieron dos modelos de redes neuronales para esta simulación, el primero es el modelo RMCS donde se propusieron distintos porcentajes de conexiones sinápticas para observar con cual de ellas la actividad de caminar enfrentándose a ciertos obstáculos y sujetar varios objetos se llevaba a cabo de la mejor manera y el segundo el modelo BP con diferencias temporales, por lo tanto las conclusiones particulares para el primer modelo son:

Con los distintos porcentajes en las conexiones sinápticas se obtuvieron resultados de aprendizaje promedio bastante bajos tanto para un individuo sano como para uno que sufrió un paro cardiorespiratorio. Sin embargo, al analizar los resultados nos percatamos de un resultado muy importante y además interesante, aunque se tuvieron aprendizajes bajos, mientras el número de conexiones sinápticas excitatorias aumentaba, también se obtenían más casos en que si lograba aprender, es decir al realizar la clasificación de las gráficas el total de gráficas **NA** disminuye y en consecuencia el total de gráficas **AV** y **ANV** era mayor.

Para el problema de dificultad al caminar:

Al analizar la última columna de la tabla 4.2 donde se tiene el total de simulaciones en las que se logró aprender las 4 respuestas correctas podemos observar que tanto para el individuo sano como para el que sufrió un paro cardiorespiratorio se obtiene un mayor número de simulaciones cuando la conexión sináptica es 100 % excitatorias -

## 5. CONCLUSIONES

---

0 % inhibitorias sin embargo es poco probable que a nivel biológico se de una conexión neuronal de ese modo, por lo tanto descartando este porcentaje de conexiones notamos que en el caso del individuo sano con conexiones 30 % excitatorias - 70 % inhibitorias es donde se obtienen 25, el mayor número de simulaciones que aprenden las 4 respuestas correctas por lo que se podría decir que fue la que mejor se comporta para desempeñar la actividad de caminar de manera normal y poder ignorar cualquier tipo de obstáculo, sin embargo en todos los porcentajes propuestos la cantidad de respuestas correctas que más se obtuvieron fueron 2 y 3, por lo tanto al tomar como límite sólo 3 respuestas correctas, el porcentaje de conexiones que obtiene el mayor número de simulaciones con 3 respuestas correctas es el 80 % excitatorias - 20 % inhibitorias, analizando estas situaciones se concluye que la conexión que daría mejores resultados de aprendizaje para un individuo sano es la 80 % excitatorias - 20 % inhibitorias, agregando además que esta conexión tiene la característica de poseer memoria a largo plazo ya que los aprendizajes siempre fueron estables, no se presentaron fluctuaciones que dieran los indicios de que lograba aprender y en un corto tiempo olvidaba ese aprendizaje, si no que aprendía e incrementaba ese conocimiento manteniéndose de este modo hasta el final del tiempo de aprendizaje, característica que no se presenta en las conexiones 30 % excitatorias - 70 % inhibitorias.

Para el caso de un individuo que sufrió un paro cardiorrespiratorio hacemos el mismo análisis, en el caso 30 % excitatorias - 70 % inhibitorias se tienen 5 simulaciones en las que se logra aprender las 4 respuestas correctas, sin embargo 5 de 251 es un número poco significativo, al tomar como límite sólo 3 respuestas correctas tenemos que las conexiones 40 % excitatorias - 60 % inhibitorias es en la que se obtiene el mayor número de simulaciones con 3 respuestas correctas, por lo tanto se concluye que la conexión que daría mejores resultados de aprendizaje para un individuo que sufrió un paro cardiorrespiratorio es la 40 % excitatorias - 60 % inhibitorias, retomando la característica de la memoria a largo plazo que se presenta a partir de la conexión 70 % excitatorias - 30 % inhibitorias, se concluye que a pesar de que los mejores resultados se dan con unas conexiones que no poseen esta característica, este resultado no está fuera de la realidad ya que al sufrir una lesión cerebral una de las secuelas que se pueden sufrir es precisamente esta, serios problemas con la memoria a largo plazo debido a la pérdida o debilitamiento en las conexiones sinápticas que sufren tras la lesión.

Para el problema de dificultad con tareas de motricidad fina:

Al analizar la última columna de la tabla 4.4 donde se tiene el total de simulaciones en las que se logró aprender las 4 respuestas correctas podemos observar al igual que en problema anterior que tanto para el individuo sano como para el que sufrió un paro cardiorrespiratorio se obtiene un mayor número de simulaciones cuando la conexión sináptica es 100 % excitatorias - 0 % inhibitorias sin embargo es poco probable que a nivel biológico se de una conexión neuronal de ese modo, por lo tanto descartando este porcentaje de conexiones notamos que en el caso del individuo sano con conexiones

---

50 % excitatorias - 50 % inhibitorias se obtienen 243 simulaciones que aprenden las 4 respuestas correctas, con conexiones 80 % excitatorias - 20 % inhibitorias se obtienen 237 simulaciones y con las conexiones 90 % excitatorias - 10 % inhibitorias se obtienen 223 simulaciones con 4 respuestas correctas, por lo tanto haciendo el análisis en el caso 50 % - 50 % se tiene el mayor número de simulaciones con 4 respuestas correctas, sin embargo queda descartado ya que en los casos 80 % - 20 % y 90 % - 10 % el número de simulaciones con comportamiento no valido es menor, se tienen 2 y 0 simulaciones respectivamente, por lo tanto analizando solo estos dos casos es más significativo las 14 simulaciones que se tienen de diferencia donde se obtienen las 4 respuestas correctas que las 2 simulaciones de diferencia en las que se obtuvo un comportamiento no valido, es decir donde no se logró aprender nada, por lo tanto se concluye que con las conexiones 80 % excitatorias - 20 % inhibitorias es con la que mejor se comporta para desempeñar la actividad de sujetar objetos de dimensión media-pequeña agregando además que al igual que en el problema anterior esta conexión tiene la característica de poseer memoria a largo plazo ya que los aprendizajes siempre fueron estables, no se presentaron fluctuaciones que dieran los indicios de que lograba aprender y en un corto tiempo olvidaba ese aprendizaje, si no que aprendía e incrementaba ese conocimiento manteniéndose de este modo hasta el final del tiempo de aprendizaje.

Para el caso de un individuo que sufrió un paro cardiorespiratorio con las conexiones 50 % excitatorias - 50 % inhibitorias se tienen 144 simulaciones en las que se logra aprender las 4 respuestas correctas, por lo tanto se concluye que la conexión que daría mejores resultados de aprendizaje en la actividad de sujetar objetos de dimensión media- pequeña para un individuo que sufrió un paro cardiorespiratorio es la 50 % excitatorias - 50 % inhibitorias, ahora hablando de la característica de la memoria a largo plazo que se presenta a partir de la conexión 70 % excitatorias - 30 % inhibitorias, se concluye que a pesar de que los mejores resultados se dan con unas conexiones que no poseen esta característica, este resultado no está fuera de la realidad ya que al sufrir una lesión cerebral una de las secuelas que se pueden sufrir es precisamente esta, serios problemas con la memoria a largo plazo debido a la pérdida o debilitamiento en las conexiones sinápticas que sufren tras la lesión.

Todos estos resultados fueron corroborados al obtener las funciones de densidad de probabilidad para cada uno de los histogramas que se realizaron en cada uno de los problemas.

Al momento de generar los archivos aleatorios "SynapticWeights.xlsx" con cada uno de los porcentajes de conexiones no se planeó que la distribución de conexiones sinápticas excitatorias e inhibitorias fuera una distribución normal, al momento de realizar el análisis de los archivos correspondientes al componente de memoria combinatoria Cj donde se obtuvieron los porcentajes de conexiones sinápticas excitatorias e inhibitorias que influyen en los 10,000 vecindarios sinápticos correspondientes a cada neurona de salida nos dimos cuenta que esta distribución era igual en cada grupo de vecindarios lo

## 5. CONCLUSIONES

---

que nos hizo llegar a la conclusión de que si en cada simulación se tienen las mismas características hablando de las conexiones sinápticas, por lo tanto nos lleva a concluir que no solo el tipo de conexión (excitatoria o inhibitoria) tiene un papel importante si no también influye mucho cómo se realizan estas conexiones, es decir la procedencia de las neuronas de entrada, lo que corresponde a los archivos “Connections.xlsx”.

Con esta hipótesis se realizó un análisis de clasificación para estos datos con el algoritmo DBSCAN, obteniendo como resultado que la agrupación de los datos se da de mejor manera obteniendo menos puntos de ruido en las simulaciones con aprendizajes mayores que en las de los aprendizajes menores, lo que nos lleva a pensar que entre mejor sea la agrupación de los datos de conexiones y sus respectivos pesos sinápticos mejor serán los aprendizajes, por ejemplo en el caso de las conexiones 100 % excitatorias - 100 % inhibitorias para la dificultad al caminar como para la dificultad con tareas de motricidad fina se obtiene una cantidad mínima de puntos de ruido y los aprendizajes obtenidos con esos porcentajes de conexión fueron los mejores llegando a obtener 0 simulaciones con aprendizaje NA.

Para el modelo BP con Diferencias Temporales se puede concluir que fue muy eficiente ya que tanto para un individuo sano como para uno que sufrió un paro cardio-respiratorio se logró obtener un error de 0 según la máquina computadora, por lo que se tienen unas predicciones exactas para los dos valores de  $\alpha$  propuestos, sin embargo en el caso del  $\alpha$  más cercano a 1 se tuvieron complicaciones que solo pudieron ser resueltas disminuyendo el total de neuronas de la capa oculta.

Tanto para el problema de dificultad para caminar como con tareas de motricidad fina se obtuvo un mayor número de conexiones sinápticas inhibitorias en el caso del individuo que sufrió un paro cardiorespiratorio con respecto a los resultados del individuo sano.

Por lo tanto, nos damos cuenta que los resultados de los dos modelos concuerdan ya que en los dos para un individuo que sufrió un paro cardiorespiratorio se tiene un número mayor de conexiones sinápticas inhibitorias respecto a las necesarias para un individuo sano para poder desempeñar actividades de la vida cotidiana de la mejor manera y no presentan la característica de la memoria a largo plazo en el caso del modelo RMCS.

### **Conclusión General:**

El cerebro es un órgano complejo en el cual muchas secciones trabajan en conjunto, las sinapsis posibilitan la conexión entre nuestras neuronas, un requisito indispensable para que nuestros impulsos nerviosos viajen. Sin ellas, nuestro cerebro estaría desconectado y seríamos incapaces de realizar las distintas funciones de la vida cotidiana.

---

Conocer la combinatoria de conexiones necesarias para llevar a cabo ciertas actividades es algo que hasta el momento nos elude, sin embargo se tienen teorías de cómo funciona el cerebro al realizar cualquier actividad de la vida diaria, se conocen las consecuencias que sufren estas conexiones al sufrir algún daño cerebral, sin embargo no existe un modelo matemático que simule este proceso de manera exacta, la inteligencia artificial es una herramienta que nos permite realizar simulaciones para representar este proceso que hasta la fecha resulta desconocido.

Tras la implementación de los dos modelos de redes neuronales artificiales propuestas para este trabajo concluimos que los resultados obtenidos no están alejados de la realidad, se sabe que al sufrir un daño cerebral las conexiones sinápticas se ven afectadas, perdiéndose conexiones que muchas veces no se pueden volver a regenerar o debilitándolas, por lo tanto al concluir que una persona que sufrió un paro cardiorespiratorio tiene más conexiones inhibitorias que excitatorias para desempeñar actividades diarias no está lejos de lo que se conoce en la teoría ya que las conexiones inhibitorias dificultan la aparición del potencial de acción en las neuronas lo que hace que esta persona no pueda realizar las actividades de la misma manera que un individuo sano y en consecuencia de este bloqueo o disminución del potencial de acción aparecen las secuelas como las mioclonías.

Por lo tanto a rasgos generales se concluye que con la implementación de los dos modelos de redes neuronales artificiales propuestos se obtuvieron resultados favorables y congruentes con la realidad.

Para poder llegar a estas conclusiones no fue suficiente la implementación del modelo, si no que para poder interpretar los resultados fue necesario implementar técnicas de probabilidad, al tener que realizar clasificaciones tanto de comportamiento del aprendizaje como de los valores obtenidos en los aprendizajes de cada una de las simulaciones y con esto obtener gráficos de frecuencias y funciones de densidad de probabilidad ya que se obtuvieron aprendizajes promedio muy bajos que no nos decían mucho, además se debían contemplar varios aspectos, entre ellos el tipo de comportamientos de aprendizaje que se obtenía con el que llegamos a concluir que en algunos casos se tenía presente una característica muy importante, que es la memoria a largo plazo y otro de los aspectos era el nivel de respuestas correctas que lograba aprender ya que el objetivo principal era poder desempeñar actividades de la vida diaria de la mejor manera, o sea saber responder de la mejor manera ante cualquier situación que se presente.

Sin embargo se tienen varios aspectos con los que se pudiera experimentar para ampliar esta información, pero algunos de ellos tendrían un alto costo computacional, a continuación se mencionan aspectos que quedan como trabajo a futuro.

### **Trabajo a futuro:**

- Aumentar los niveles de conexiones, es decir agregar capas ocultas a la red neuronal artificial.
- Aumentar las conexiones sinápticas en los vecindarios de sinapsis (para este trabajo lo máximo fueron 4), aunque este aumento genera costo computacional.
- Aumentar el número de simulaciones para generar una mayor cantidad de información.
- Generar los archivos correspondientes a las conexiones sinápticas y los pesos sinápticos usando distintas distribuciones de probabilidad (para este trabajo fue una distribución normal).
- Experimentar con distintos estados iniciales para las neuronas sensoriales de la capa de entrada (en nuestro caso todas se encontraban inactivas).
- Encontrar la función de probabilidad usando el criterio de las distribuciones alfa-estables para poder hacer un estudio cuantitativo de probabilidades y no solo de modo cualitativo como se realizó en este trabajo.

---

Apéndice A

## Apéndice

---

En este apartado se muestran algoritmos en forma de pseudocódigo para cada uno de los modelos de redes neuronales propuestas en este trabajo.

Elementos correspondientes al modelo RMCS tales como códigos en lenguaje python con los que fueron generados los archivos de las conexiones sinápticas y los pesos sinápticos para cada uno de los problemas planteados.

Se tiene el análisis del componente de memoria combinatoria Cj mismo que es implementado con los dos modelos, RMCS y BP con diferencias temporales.

Se encuentra el README del contenido de la carpeta “El aprendizaje por refuerzo como modelo de actividad cerebral“ localizada en OneDrive, donde se pueden encontrar gráficas y archivos correspondientes a todos los resultados obtenidos durante el desarrollo de este trabajo.

Finalmente se tienen los resultados detalladamente de cada experimento para los modelos RMCS y BP con diferencias temporales.

## A.1. Pseudocódigo de algoritmo para el modelo RMCS

```
00  Definir parámetros:
01      inputNeurons: Número de neuronas de entrada
02      outputNeurons: Número de neuronas de salida
03      numClusters: Número de grupos sinápticos en una neurona de salida (Neuronas
04      en la capa oculta por cada neurona de la capa de salida)
05      clusterSize: Número de sinapsis en un clúster sináptico (clúster: Neurona de la
06      capa oculta)
07      totalLearningObjectPresentations: Número total de presentaciones de objetos de
08      aprendizaje
09      numTestObjects: Número de objetos de prueba
10      weakPositiveReward: Recompensa positiva fuerte
11      strongPositiveReward: Recompensa positiva débil
12      strongNegativeReward: Recompensa negativa fuerte
13      numClustersToFire: Número de grupos excitados con un peso de al menos 1 que
14      dispara una neurona motora
15      numSimulations: Número total de simulaciones para promediar
16
17  Ejecutar:
18  Para iSimulation=1 hasta iSimulation=numSimulations
19
20      Inicializar:
21      Clústers aleatorios
22       $w_{ij}$ : Pesos sinápticos aleatorios (1=Sinapsis Excitatoria, -1=Sinapsis
23      Inhibitoria)
24       $\alpha_j$ : Pesos de vecindarios sinápticos (Calcular de acuerdo con el
25      Componente  $C_j$ )
26
27      Para LearningTime=1 hasta LearningTime=totalLearningObjectPresentations
28
29          Seleccionar al azar el objeto de aprendizaje
30          Obtener la salida activada en respuesta al objeto de aprendizaje
31          Si no se activo ninguna salida, generar un disparo de prueba aleatorio
32          Obtener la recompensa por la acción seleccionada
33          Actualizar los pesos de vecindario sináptico
34
35          Para iTestObject=1 hasta iTestObject=numTestObjects
36
37              Obtener la salida activada en respuesta al objeto de prueba
38              Registrar si la acción seleccionada fue correcta o no
39
40      ¡¡Entrenamiento Terminado!!
```

## A.2. Pseudocódigo de algoritmo para modelo BP con diferencias temporales

```
00  Definir parámetros:
01      totalData: Número de objetos de aprendizaje
02      epochs: Número de épocas
03      inputNeurons: Número de neuronas de entrada
04      outputNeurons: Número de neuronas de salida
05      hiddenNeurons: Número de neuronas en la capa oculta
06      totalDataTest: Número de objetos de prueba

07  Inicializar:
08       $w_{ij}$ : Pesos sinápticos aleatorios (1=Sinapsis Excitatoria, -1=Sinapsis Inhibitoria)
09       $\alpha_j$ : Pesos de vecindarios sinápticos aleatorios (1=Sinapsis Excitatoria,
10      -1=Sinapsis Inhibitoria)

10  Ejecutar:
11      Para epoch=1 hasta epoch=epochs
12          Para data=1 hasta data=totalData
13              Calcular la función de propagación  $h$ 
14              Calcular la función de activación  $F(h)$ 
15              Obtener la predicción (Salida de la red)
16              Calcular el error entre la predicción y la salida deseada
17              Actualizar pesos sinápticos  $w_{ij}$  con algoritmo de diferencias
18              temporales
19              Actualizar pesos de vecindarios sinápticos  $\alpha_j$  con algoritmo de
20              diferencias temporales

19  Guardar los valores de los pesos sinápticos y pesos de vecindarios sináptico

20  ¡¡Entrenamiento Terminado!!

21  Para data=1 hasta data=totalDataTest
22      Obtener la predicción con los pesos sinápticos y pesos de vecindario
23      sinápticos guardados al final del entrenamiento
24      Graficar la predicción

24  ¡¡Etapa de Prueba Terminada!!
```

### A.3. Código para generar archivos Connections.xlsx para la dificultad para caminar

```
# -*- coding: utf-8 -*-
"""
Created on Thu Nov 14 17:39:48 2019

@author: Karina Sánchez
"""

import random
import numpy as np
import pandas as pd

outputNeurons = 5      # Neuronas de salida
numClusters = 10000    # Neuronas por cada neurona de salida
clusterSize = 4        # Conexiones totales en cada neurona de la capa oculta
numSimulations = 251  # Número de simulaciones

""" Generamos los archivos de Connections """

array = np.zeros([outputNeurons*numClusters,clusterSize], dtype=np.int32)

for k in range (numSimulations): # Para cada simulación (desde 0 hasta 250)
    for i in range (len(array)):
        for j in range (clusterSize):
            """Genera números aleatorios entre 0 y 11, corresponde a las 12
neuronas de la capa de entrada """
            array[i][j]= random.randint(0,11)

            """Genera el archivo Connections"""
            Connections=pd.DataFrame(array,columns=('Conexion 1', 'Conexion 2', 'Conexion
3', 'Conexion 4'))
            Connections.to_excel('Connections_'+ str(k) + '.xlsx',sheet_name='Connections')
```

## A.4. Código para generar archivos SynapticWeights.xlsx para la dificultad para caminar

```
# -*- coding: utf-8 -*-
"""
Created on Thu Nov 14 17:39:48 2019

@author: Karina Sánchez
"""

import random
import numpy as np
import pandas as pd

outputNeurons = 5          # Neuronas de salida
numClusters = 10000        # Neuronas por cada neurona de salida
clusterSize = 4            # Conexiones totales en cada neurona de la capa oculta
numSimulations = 251      # Número de simulaciones

""" Semilla para números aleatorios """
random.seed(12345678)

"""Creamos la lista donde se guardan los valores 1 y -1 """
listValores=[]
for i in range(0,140000): #140,000 veces el valor 1 corresponde al 70% de
sinapsis excitatorias
    listValores.append(1)
for j in range(140000,200000): #60,000 veces el valor -1 corresponde al 30% de
sinapsis inhibitorias
    listValores.append(-1)

""" Mezclamos los valores de la lista para que no queden cargados """
random.shuffle(listValores)

""" Generamos la tabla de SynapticWeights usando los valores (listValores) según la
lista de posición (position) """

array = np.zeros([outputNeurons*numClusters,clusterSize], dtype=np.int32)
for k in range (numSimulations):
    """ Creamos una lista que contiene las posiciones aleatorias y sin repetición
para generar la tabla SynapticWeights """
    position = random.sample(range(0,200000),200000)
    cont=0
    for i in range (len(array)):
        for j in range (clusterSize):
            array[i][j]= listValores[position[cont]]
            cont = cont+1

SynapticWeights=pd.DataFrame(array,columns=('input1','input2','input3','input4'))
SynapticWeights.to_excel('64SynapticWeights_'+ str(k) +
'.xlsx',sheet_name='SynapticWeights')
```

## A.5. Código para generar archivos Connections.xlsx para la dificultad con tareas de motricidad fina

```
# -*- coding: utf-8 -*-
"""
Created on Thu Nov 14 17:39:48 2019

@author: Karina Sánchez
"""

import random
import numpy as np
import pandas as pd

outputNeurons = 4      # Neuronas de salida
numClusters = 10000    # Neuronas por cada neurona de salida
clusterSize = 4        # Conexiones totales en cada neurona de la capa oculta
numSimulations = 251  # Número de simulaciones

""" Generamos los archivos de Connections """

array = np.zeros([outputNeurons*numClusters,clusterSize], dtype=np.int32)

for k in range (numSimulations): # Para cada simulación (desde 0 hasta 250)
    for i in range (len(array)):
        for j in range (clusterSize):
            """Genera números aleatorios entre 0 y 11, corresponde a las 12
neuronas de la capa de entrada """
            array[i][j]= random.randint(0,11)

            """Genera el archivo Connections"""
            Connections=pd.DataFrame(array,columns=('Conexion 1','Conexion 2','Conexion
3','Conexion 4'))
            Connections.to_excel('Connections_'+ str(k) + '.xlsx',sheet_name='Connections')
```

## A.6. Código para generar archivos SynapticWeights.xlsx para la dificultad con tareas de motricidad fina

```
# -*- coding: utf-8 -*-
"""
Created on Thu Nov 14 17:46:22 2019

@author: Karina Sánchez
"""

import random
import numpy as np
import pandas as pd

outputNeurons = 4          # Neuronas de salida
numClusters = 10000        # Neuronas por cada neurona de salida
clusterSize = 4            # Conexiones totales en cada neurona de la capa oculta
numSimulations = 251      # Número de simulaciones

""" Semilla para números aleatorios """
random.seed(12345678)

"""Creamos la lista donde se guardan los valores 1 y -1 """
listValores=[]
for i in range (0,32000): #32,000 veces el valor 1 corresponde al 20% de sinapsis
    excitatorias
    listValores.append(1)
for j in range (32000,160000): #128,000 veces el valor -1 corresponde al 80% de
    sinapsis inhibitorias
    listValores.append(-1)

""" Mezclamos los valores de la lista para que no queden cargados """
random.shuffle(listValores)

""" Generamos la tabla de SynapticWeights usando los valores (listValores) según la
lista de posición (position) """

array = np.zeros([outputNeurons*numClusters,clusterSize], dtype=np.int32)
for k in range (numSimulations):
    """ Creamos una lista que contiene las posiciones aleatorias y sin repetición
para generar la tabla SynapticWeights """
    position = random.sample(range(0,160000),160000)
    cont=0
    for i in range (len(array)):
        for j in range (clusterSize):
            array[i][j]= listValores[position[cont]]
            cont = cont+1

SynapticWeights=pd.DataFrame(array,columns=('input1','input2','input3','input4'))
SynapticWeights.to_excel('64SynapticWeights_'+ str(k) +
'.xlsx',sheet_name='SynapticWeights')
```

## A.7. Análisis del Componente de Memoria Combinatoria C<sub>j</sub>

$$C_j(X) = \gamma_j H(n_j - n_j^* - \bar{n}_j)$$

Donde:

- Sinapsis Excitatorias Activas de  $N_j$

$$n_j : n_j = \sum_{w_{ij} > 0} w_{ij} X_i$$

- Sinapsis Excitatorias de  $N_j$

$$n_j^* : n_j^* = \sum_{w_{ij} > 0} w_{ij} > 0$$

- Sinapsis Inhibitorias Activas de  $N_j$

$$\bar{n}_j : \bar{n}_j = - \sum_{w_{ij} < 0} w_{ij} X_i \geq 0$$

- Función  $H(n)$

$$H(n) : H(n) = \begin{cases} 1, & n \geq 0 \\ 0, & n < 0 \end{cases}$$

- Pesos de Vecindario  $N_j$

$$\gamma_j : \gamma_j = \begin{cases} 1, & \text{si } N_j \text{ está excitado, es decir } H(n) = 1, \\ 0, & \text{si } N_j \text{ no está excitado, es decir } H(n) = 0. \end{cases}$$

Como condición inicial tenemos que para todo  $X_i$  del conjunto de vectores de entrada  $X$ ,  $X_i = 0$  por lo tanto  $n_j = 0$  y  $\bar{n}_j$  entonces

$$H(n_j - n_j^* - \bar{n}_j) = H(0 - n_j^* - 0)$$

Además  $n_j^* \geq 0$  por lo tanto:

$$\text{Si } n_j^* > 0 \rightarrow H(0 - n_j^* - 0) = H(-n_j^*) = 0 \rightarrow \gamma_j = 0 \rightarrow C_j(X) = 0$$

$$\text{Si } n_j^* = 0 \rightarrow H(0 - 0 - 0) = H(0) = 1 \rightarrow \gamma_j = 1 \rightarrow C_j(X) = 1$$

Por lo tanto, cuando en el vecindario sináptico (neurona de la capa oculta) no se tiene ninguna conexión sináptica excitatoria, el vecindario tiene un peso sináptico inicial de  $\gamma_j = 1$ .

Por lo tanto, las conexiones sinápticas que tienen mayor influencia al inicio del aprendizaje cuando se tiene como condición inicial que  $X = 0$  son las conexiones inhibitorias.

## A.8. README

A continuación se describe el contenido de la carpeta “El aprendizaje por refuerzo como modelo de actividad cerebral” localizada en OneDrive a la cual se puede acceder desde la siguiente liga:

[https://comunidadunammx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25\\_comunidad\\_unam\\_mx/E17AYAqON690t8003gKra0kBOln8yopMYvwoWRGzGeToZw?e=e19oTm](https://comunidadunammx-my.sharepoint.com/:f:/g/personal/kkarinasanchez25_comunidad_unam_mx/E17AYAqON690t8003gKra0kBOln8yopMYvwoWRGzGeToZw?e=e19oTm)

Contiene 3 tipos de carpetas correspondientes a los resultados del modelo RMCS:

- **Memoria Combinatoria:** Contiene los resultados correspondientes al calculo del componente Cj para cada simulación.
- **Resultados Aprendizaje RMCS:** Contiene los resultados del aprendizaje donde se registran las respuestas correctas para cada simulación.
- **Gráficas y resumen de aprendizaje:** Gráficas de los resultados, tablas de los datos obtenidos en el conteo de conexiones excitatorias e inhibitorias del componente Cj y clasificación de comportamientos validos para cada uno de los experimentos realizados para los problemas de la dificultad para caminar y la dificultad con tareas de motricidad fina para un individuo normal y un individuo que sufrió un paro cardiorespiratorio.

Para los resultados del modelo BP con diferencias temporales solo tenemos 2 carpetas diferentes:

- **BP Alpha 0.005:** Contiene los resultados de cada una de las redes neuronales artificiales donde el valor de  $\alpha = 0.005$ .
- **BP Alpha 0.85535:** Contiene los resultados de cada una de las redes neuronales artificiales donde el valor de  $\alpha = 0.85535$ .

Para identificar los archivos con los resultados para el problema de manzanas y piedras que es usado para validar el modelo llamaremos a la carpeta “Apple and Stone”.

Para identificar los archivos con los resultados para el problema de dificultad para caminar usamos la palabra “Obstacles”, cuando se refiere a un individuo normal usamos “PNormal” y para un individuo que sufrió un paro cardiorespiratorio usamos “PPCR”, para indicar los distintos porcentajes en las conexiones sinápticas excitatorias-inhibitorias usamos “Synaptic excitatorias(%)-inhibitorias(%)” por lo tanto las carpetas para este caso serian:

Obstacles PNormal Synaptic 10-90	Obstacles PPCR Synaptic 10-90
Obstacles PNormal Synaptic 20-80	Obstacles PPCR Synaptic 20-80
Obstacles PNormal Synaptic 30-70	Obstacles PPCR Synaptic 30-70
Obstacles PNormal Synaptic 40-60	Obstacles PPCR Synaptic 40-60
Obstacles PNormal Synaptic 50-50	Obstacles PPCR Synaptic 50-50
Obstacles PNormal Synaptic 60-40	Obstacles PPCR Synaptic 60-40
Obstacles PNormal Synaptic 70-30	Obstacles PPCR Synaptic 70-30
Obstacles PNormal Synaptic 80-20	Obstacles PPCR Synaptic 80-20
Obstacles PNormal Synaptic 90-10	Obstacles PPCR Synaptic 90-10
Obstacles PNormal Synaptic 100-0	Obstacles PPCR Synaptic 100-0

Ahora para identificar los archivos con los resultados para el problema de dificultad con tareas de motricidad fina usamos la palabra “Objects”, cuando se refiere a un individuo normal usamos “PNormal” y para un individuo que sufrió un paro cardio-respiratorio usamos “PPCR”, para indicar los distintos porcentajes en las conexiones sinápticas excitatorias-inhibitorias usamos “Synaptic excitatorias(%) -inhibitorias(%)” por lo tanto las carpetas para este caso serian:

Objects PNormal Synaptic 10-90	Objects PPCR Synaptic 10-90
Objects PNormal Synaptic 20-80	Objects PPCR Synaptic 20-80
Objects PNormal Synaptic 30-70	Objects PPCR Synaptic 30-70
Objects PNormal Synaptic 40-60	Objects PPCR Synaptic 40-60
Objects PNormal Synaptic 50-50	Objects PPCR Synaptic 50-50
Objects PNormal Synaptic 60-40	Objects PPCR Synaptic 60-40
Objects PNormal Synaptic 70-30	Objects PPCR Synaptic 70-30
Objects PNormal Synaptic 80-20	Objects PPCR Synaptic 80-20
Objects PNormal Synaptic 90-10	Objects PPCR Synaptic 90-10
Objects PNormal Synaptic 100-0	Objects PPCR Synaptic 100-0

La carpeta “Memoria Combinatoria” contiene un total de 36 carpetas (descritas anteriormente para cada uno de los problemas tratados) en cada una de estas carpetas se tienen 251 archivos *.xlsx* que contiene los cálculos del componente de memoria combinatoria  $C_j$ . En la figura A.1 se presenta un ejemplo de uno de los 251 archivos *.xlsx*, en la primer columna se indica el número del vecindario de sinapsis  $N_j$  (neuronas de la capa oculta), en la siguientes columnas se muestran el total de conexiones sinápticas excitatorias, excitatorias activas, inhibitorias activas, valor de la función H, valor de gamma y por ultimo el valor  $C_j$  del vecindario de sinapsis correspondiente.

Estos archivos no se incluyen para los casos en que se tienen el 100% de las conexiones excitatorias debido a que el valor de  $C_j$  nunca cambia para cada una de las simulaciones.

## A. APÉNDICE

	A	B	C	D	E	F	G
1	Vecindario de Sinapsis	excitatorySynapses	activeExcitatorySynapses	activeInhibitorySynapses	Hfunction	gamma	CombinatorialMemoryComponent
2	0	0	0	0	1	1	1
3	1	1	0	0	0	0	0
4	2	0	0	0	1	1	1
5	3	1	0	0	0	0	0
6	4	1	0	0	0	0	0
7	5	0	0	0	1	1	1
8	6	1	0	0	0	0	0
9	7	0	0	0	1	1	1
10	8	0	0	0	1	1	1
11	9	0	0	0	1	1	1
12	10	1	0	0	0	0	0
13	11	0	0	0	1	1	1
14	12	0	0	0	1	1	1
15	13	0	0	0	1	1	1
16	14	0	0	0	1	1	1
17	15	0	0	0	1	1	1
18	16	0	0	0	1	1	1
19	17	0	0	0	1	1	1
20	18	0	0	0	1	1	1
21	19	0	0	0	1	1	1
22	20	1	0	0	0	0	0
23	21	0	0	0	1	1	1
24	22	0	0	0	1	1	1
25	23	0	0	0	1	1	1
26	24	0	0	0	1	1	1
27	25	0	0	0	1	1	1
28	26	0	0	0	1	1	1
29	27	1	0	0	0	0	0

**Figura A.1:** Formato de archivo contenido en “Memoria Combinatoria”.

La carpeta “Resultados Aprendizaje RMCS” contiene 5 carpetas, estas se definen de acuerdo al problema ya sea para “Apple and Stone”, “Obstacles” u “Objects” y al individuo tratado, es decir “PNormal” o “PPCR”, por lo tanto las carpetas incluidas son:

Apple and Stone  
 Obstacles PNormal  
 Obstacles PPCR  
 Objects PNormal  
 Objects PPCR

En la figura A.2 se muestra una parte del archivo donde se registra en la primer columna el número de simulación, en las columnas siguientes se tiene el tiempo de aprendizaje es decir la presentación del objeto de aprendizaje (168 presentaciones totales), número de respuestas donde se disparó (activó) una sola neurona de salida, número de respuestas correctas, número de veces que lanzo una manzana y finalmente el número de veces que comió una piedra. En este archivo se encuentra el total de registros para las 501 simulaciones realizadas.

	A	B	C	D	E	F
1	NumSimulation	LearningTime	iCountHadOneFiringOutput	iCountCorrectAnswers	iCountPushedOffApples	iCountAteStones
2	0	0	0	0	0	0
3	0	1	0	0	0	0
4	0	2	0	0	0	0
5	0	3	0	0	0	0
6	0	4	0	0	0	0
7	0	5	0	0	0	0
8	0	6	0	0	0	0
9	0	7	0	0	0	0
10	0	8	0	0	0	0
11	0	9	0	0	0	0
12	0	10	0	0	0	0
13	0	11	0	0	0	0
14	0	12	0	0	0	0
15	0	13	0	0	0	0
16	0	14	0	0	0	0
17	0	15	0	0	0	0
18	0	16	0	0	0	0
19	0	17	0	0	0	0
20	0	18	0	0	0	0
21	0	19	0	0	0	0
22	0	20	0	0	0	0
23	0	21	0	0	0	0
24	0	22	0	0	0	0
25	0	23	0	0	0	0
26	0	24	0	0	0	0
27	0	25	0	0	0	0
28	0	26	2	2	0	0
29	0	27	2	2	0	0

**Figura A.2:** Formato de archivo contenido en “Resultados Aprendizaje” para “Apple and Stone”.

En la figura A.3 se muestra una parte del archivo donde se registra en la primer columna el número de simulación, en las columnas siguientes se tiene el tiempo de aprendizaje (200 presentaciones totales), número de respuestas donde se disparó una sola neurona de salida, número de respuestas correctas, número de veces que sufre mioclonías, número de veces que cae, número de veces que caminó normal, número de veces que se detiene un momento y finalmente el número de veces que se niega a caminar.

	A	B	C	D	E	F	G	H	I
1	NumSimulation	LearningTime	iCountHadOneFiringOutput	iCountCorrectAnswers	iCountSufferedMyoclonus	iCountTheFallOut	iCountWalkedNormal	iCountTheStopped	iCountTheRefuses
2	0	0	0	0	0	0	0	0	0
3	0	1	0	0	0	0	0	0	0
4	0	2	0	0	0	0	0	0	0
5	0	3	0	0	0	0	0	0	0
6	0	4	0	0	0	0	0	0	0
7	0	5	0	0	0	0	0	0	0
8	0	6	0	0	0	0	0	0	0
9	0	7	0	0	0	0	0	0	0
10	0	8	0	0	0	0	0	0	0
11	0	9	0	0	0	0	0	0	0
12	0	10	0	0	0	0	0	0	0
13	0	11	0	0	0	0	0	0	0
14	0	12	0	0	0	0	0	0	0
15	0	13	0	0	0	0	0	0	0
16	0	14	0	0	0	0	0	0	0
17	0	15	0	0	0	0	0	0	0
18	0	16	0	0	0	0	0	0	0
19	0	17	0	0	0	0	0	0	0
20	0	18	0	0	0	0	0	0	0
21	0	19	0	0	0	0	0	0	0
22	0	20	0	0	0	0	0	0	0
23	0	21	0	0	0	0	0	0	0
24	0	22	0	0	0	0	0	0	0
25	0	23	0	0	0	0	0	0	0
26	0	24	0	0	0	0	0	0	0
27	0	25	0	0	0	0	0	0	0
28	0	25	0	0	0	0	0	0	0
29	0	27	0	0	0	0	0	0	0

**Figura A.3:** Formato de archivo contenido en “Resultados Aprendizaje” para “Obstacles”.

En la figura A.4 se muestra una parte del archivo donde se registra en la primer

## A. APÉNDICE

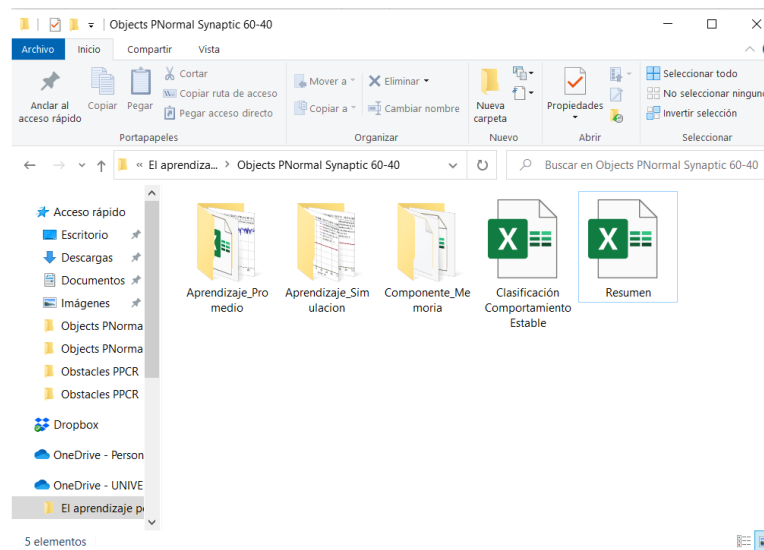
columna el número de simulación, en las columnas siguientes se tiene el tiempo de aprendizaje (200 presentaciones totales), número de respuestas donde se disparó una sola neurona de salida, número de respuestas correctas, número de veces que sujeta de manera normal, número de veces que sufre mioclonías, número de veces que arrojó el objeto al piso y finalmente el número de veces que se negó a sujetar el objeto.

	A	B	C	D	E	F	G	H
1	NumSimulation	LearningTime	iCountHadOneFiringOutput	iCountCorrectAnswers	iCountHoldNormal	iCountSufferedMyoclonus	iCountThrew	iCountHeRefused
2	0	0	0	0	0	0	0	0
3	0	1	0	0	0	0	0	0
4	0	2	0	0	0	0	0	0
5	0	3	0	0	0	0	0	0
6	0	4	0	0	0	0	0	0
7	0	5	0	0	0	0	0	0
8	0	6	0	0	0	0	0	0
9	0	7	0	0	0	0	0	0
10	0	8	2	2	0	2	0	0
11	0	9	2	2	0	2	0	0
12	0	10	2	2	0	2	0	0
13	0	11	2	2	0	2	0	0
14	0	12	2	2	0	2	0	0
15	0	13	2	2	0	2	0	0
16	0	14	2	2	0	2	0	0
17	0	15	2	2	0	2	0	0
18	0	16	2	2	0	2	0	0
19	0	17	2	2	0	2	0	0
20	0	18	2	2	0	2	0	0
21	0	19	2	2	0	2	0	0
22	0	20	2	2	0	2	0	0
23	0	21	2	2	0	2	0	0
24	0	22	2	2	0	2	0	0
25	0	23	2	2	0	2	0	0
26	0	24	2	2	0	2	0	0
27	0	25	2	2	0	2	0	0
28	0	26	2	2	0	2	0	0
29	0	27	2	2	0	2	0	0

**Figura A.4:** Formato de archivo contenido en “Resultados Aprendizaje” para “Objects”.


Las carpetas que contienen las gráficas, el resumen del aprendizaje y la clasificación para aprendizajes validos de cada problema son en total 41, estas carpetas son nombradas bajo el criterio ya mencionado anteriormente, referencia para el problema, o sea “Obstacles” u “Objects”, individuo tratado , es decir “PNormal” o “PPCR” y finalmente porcentajes en las conexiones sinápticas excitatorias-inhibitorias, es decir “Synaptic excitatorias-inhibitorias”. Los nombres completos de estas carpetas se listaron anteriormente.

El contenido de cada una de estas 41 carpetas se muestra en la figura A.5



**Figura A.5:** Contenido de las carpetas donde se contienen las gráficas y resumen del aprendizaje.

En la carpeta “Aprendizaje Simulación” se tienen las 251 gráficas correspondientes a los resultados de aprendizaje en cada simulación. El formato de cada una de estas gráficas se muestra en la figura A.6.



**Figura A.6:** Formato de gráficas para aprendizaje.

El contenido de la carpeta “Aprendizaje Promedio” se puede observar en la figura A.7, se tiene un archivo *.xlsx* donde se incluyen los aprendizajes promedio de cada una de las 251 simulaciones, una imagen de la gráfica de estos aprendizajes promedio y un archivo *.py* con el que se obtiene el aprendizaje promedio mayor y menor.

## A. APÉNDICE

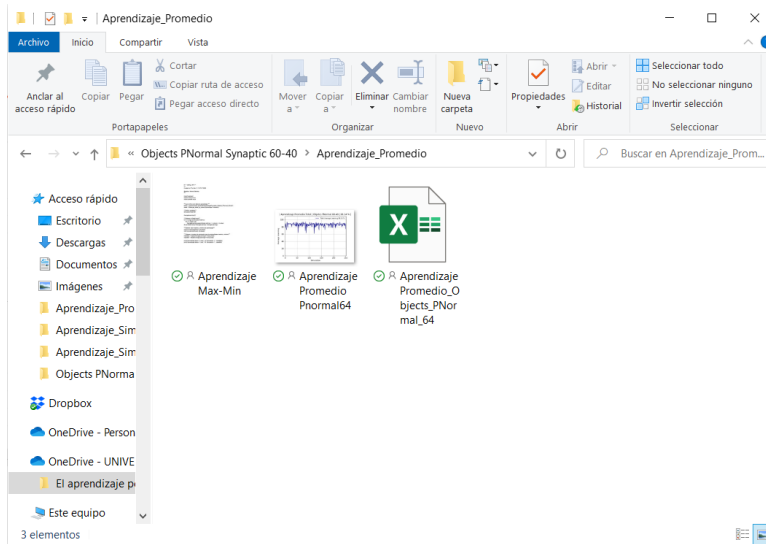


Figura A.7: Contenido de la carpeta “Aprendizaje Promedio”.

El contenido de la carpeta “Componente Memoria” se observa en la figura A.8.

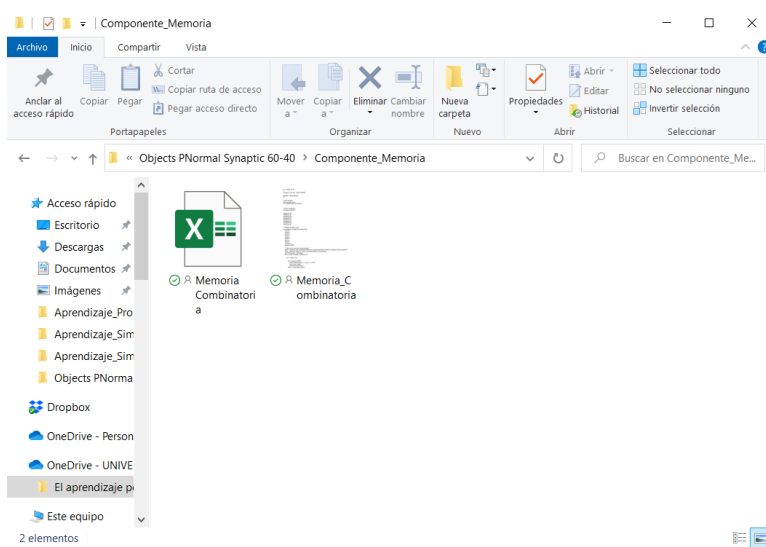


Figura A.8: Contenido de la carpeta “Aprendizaje Promedio”.

En el archivo “*Memoria Combinatoria.xlsx*” contiene el conteo total de las conexiones excitatorias e inhibitorias que influyen en los vecindarios sinápticos correspondientes a cada neurona de salida en cada una de las simulaciones, en la figura A.9 se muestra un ejemplo de este archivo. El archivo *.py* es con que se genera este archivo.

	A	L	M	N	O	P	Q	R	S	T	U
1		% Conteo de Conexiones Sinápticas									
2	Simulación	0-9999		10000-19999		20000-29999		30000-39999		40000-49999	
3		Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory
4	0	20.02	19.83	19.98	20.23	20.02	19.81	20.01	19.89	19.97	20.26
5	1	19.96	20.37	20.00	20.00	19.98	20.21	20.03	19.72	20.03	19.71
6	2	19.98	20.18	19.98	20.23	20.08	19.30	19.98	20.18	19.99	20.13
7	3	20.00	20.04	19.98	20.19	19.99	20.13	19.99	20.07	20.05	19.58
8	4	20.02	19.86	19.98	20.19	20.01	19.88	20.03	19.72	19.96	20.36
9	5	19.98	20.19	20.01	19.90	19.98	20.16	20.01	19.87	20.01	19.88
10	6	19.97	20.27	19.99	20.13	20.05	19.56	19.99	20.13	20.01	19.93

Figura A.9: Parte del archivo del análisis de la memoria combinatoria.

El archivo “Resumen.xlsx” en el que además de contener el conteo total de conexiones como en el archivo anterior, se tienen los porcentajes de esos valores, el aprendizaje promedio en cada simulación, el aprendizaje mayor y menor, el total de respuestas correctas aprendidas al final del aprendizaje, información relevante para realizar los histogramas de los aprendizajes obtenidos y la clasificación de cada una de las gráficas de aprendizaje, esta clasificación se realiza de acuerdo al siguiente criterio:

“Al analizar el comportamiento del aprendizaje en cada una de las gráficas se decidió que la parte más importante del aprendizaje es el final de este, por lo tanto se considera importante las últimas 25 presentaciones de objetos, es decir se observa el comportamiento del aprendizaje en el tiempo 175 al 200 y se consideran **NA** aquellas gráficas donde el aprendizaje no es estable o no se obtuvo ninguna respuesta correcta en el tiempo ya establecido, se etiquetan como **AV** aquellas gráficas que cumplan con un comportamiento estable por lo menos en el tiempo de aprendizaje establecido como valido y que el porcentaje de aprendizaje promedio sea igual o mayor a la media, o sea al aprendizaje promedio total (aprendizaje promedio de las 251 simulaciones) y por ultimo se consideran **ANV** las gráficas que presenten un comportamiento estable por lo menos en el tiempo de aprendizaje establecido como valido pero que el aprendizaje promedio sea menor a la media.”

En la figura A.10 se muestra una parte de este archivo.

	A	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	
1	Conteo de Conexiones Sinápticas																			
2	Simulación	10000-19999				20000-29999				30000-39999				% Conexiones Sinápticas				Aprendizaje Promedio %	Aprendizaje Max - Min	Clase (Etiqueta de Apre
3		Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory	Excitatory	Inhibitory				
4	0	15968	24104	15896	24008	15992	23856	16144	25.03	24.95	25.11	24.84	25.01	24.99	24.85	25.23	89.875		AV	
5	1	16123	23932	16068	24055	15945	24136	15864	24.87	25.19	24.93	25.11	25.06	24.91	25.14	24.79	87.625		AV	
6	2	15822	24092	15908	23861	16139	23869	16131	25.19	24.72	25.10	24.86	24.86	25.22	24.86	25.20	79.125		ANV	
7	3	15858	23994	16006	23904	16096	23960	16040	25.15	24.78	24.99	25.01	24.90	25.15	24.96	25.06	89.375		AV	
8	4	15908	24053	15947	23967	16033	23888	16112	25.10	24.86	25.06	24.92	24.97	25.05	24.88	25.18	79.875		ANV	
9	5	16121	24012	15988	24038	15962	24071	15929	24.87	25.19	25.01	24.98	25.04	24.94	25.07	24.89	76.375		ANV	
10	6	15923	24082	15918	23961	16039	23880	16120	25.08	24.88	25.09	24.87	24.96	25.06	24.88	25.19	72.5		ANV	
11	7	16174	23938	16062	24104	15896	24132	15868	24.82	25.27	24.94	25.10	25.11	24.84	25.14	24.79	75.125		NA	
12	8	15906	24022	15978	23912	16088	23972	16028	25.10	24.85	25.02	24.97	24.91	25.14	24.97	25.04	94		AV	
13	9	15951	24149	15851	23831	16169	23971	16029	25.05	24.92	25.16	24.77	24.82	25.26	24.97	25.05	91		AV	
14	10	16069	24082	15918	24055	15945	23932	16068	24.93	25.11	25.09	24.87	25.06	24.91	24.93	25.11	83.375		ANV	
15	11	15909	24026	15974	24003	15997	23880	16120	25.09	24.86	25.03	24.96	25.00	25.00	24.88	25.19	79.125		ANV	
16	12	16023	24042	15958	24061	15939	23920	16080	24.98	25.04	25.04	24.93	25.06	24.90	24.92	25.13	90		AV	
17	13	16091	24061	15939	23958	16042	24072	15928	24.91	25.14	25.06	24.90	24.96	25.07	25.08	24.89	88		AV	
18	14	15935	24072	15928	23916	16084	23947	16053	25.07	24.90	25.08	24.89	24.91	25.13	24.94	25.08	87.125		AV	
19	15	15943	24081	15919	24005	15995	23857	16143	25.06	24.91	25.08	24.87	25.01	24.99	24.85	25.22	89.875		AV	
20	16	15949	23850	16150	23989	16011	24110	15890	25.05	24.92	24.84	25.23	24.99	25.02	25.11	24.83	89		AV	
21	17	16014	23994	16006	23952	16048	24068	15932	24.99	25.02	24.99	25.01	24.95	25.08	25.07	24.89	89		AV	
22	18	16029	24091	15909	23982	16018	23956	16044	24.97	25.05	25.09	24.86	24.98	25.03	24.95	25.07	88.375		AV	
23	19	15982	23918	16082	24006	15994	24058	15942	25.02	24.97	24.91	25.13	25.01	24.99	25.06	24.91	88.25		AV	
24	20	15966	23876	16124	23939	16061	24151	15849	25.04	24.95	24.87	25.19	24.94	25.10	25.16	24.76	90		AV	
25	21	15919	24018	15982	23956	16044	23945	16055	25.08	24.87	25.02	24.97	24.95	25.07	24.94	25.09	88.625		AV	
26	22	16085	23990	16010	24150	15850	23945	16055	24.91	25.13	24.99	25.02	25.16	24.77	24.94	25.09	90.375		AV	
27	23	15889	23970	16030	23907	16093	24012	15988	25.12	24.83	24.97	25.05	24.90	25.15	25.01	24.98	87		AV	
28	24	15947	23913	16087	24169	15831	23865	16135	25.06	24.92	24.91	25.14	25.18	24.74	24.86	25.21	86.875		AV	
29	25	16104	24084	15916	23970	16030	24050	15950	24.89	25.16	25.09	24.87	24.97	25.05	25.05	24.92	85.75		ANV	

Figura A.10: Parte del archivo "Resumen".

En el archivo “*Clasificación Comportamiento Estable*” se tiene la información con la que se realizaron los histogramas de los aprendizajes (%) obtenidos únicamente en las simulaciones que previamente fueron clasificadas con comportamiento estable es decir AV y ANV.

En la figura A.11 se muestra una parte de este archivo.

	A	B	C	D	E	F	G	H	I	J
2	Simulación	Aprendizaje Promedio %	Clase (Etiqueta de Aprendizaje)	Intervalo de Clase		Dato Mayor	Dato Menor	Rango	Número de Clases	Longitud de la Clase
3						94.5	62.125	32.375	15	2.158
4	0	89.875	AV	13						
5	1	87.625	AV	12						
6	2	79.125	ANV	8						
7	3	89.375	AV	13						
8	4	79.875	ANV	9						
9	5	76.375	ANV	7						
10	6	72.5	ANV	5						
11	8	94	AV	15						
12	9	91	AV	14						
13	10	83.375	ANV	10						
14	11	79.125	ANV	8						
15	12	90	AV	13						
16	13	88	AV	12						
17	14	87.125	AV	12						
18	15	89.875	AV	13						
19	16	89	AV	13						
20	17	89	AV	13						
21	18	88.375	AV	13						
22	19	88.25	AV	13						
23	20	90	AV	13						
24	21	88.625	AV	13						
25	22	90.375	AV	14						
26	23	87	AV	12						
27	24	86.875	AV	12						
28	25	85.75	ANV	11						
29	26	85.625	ANV	11						

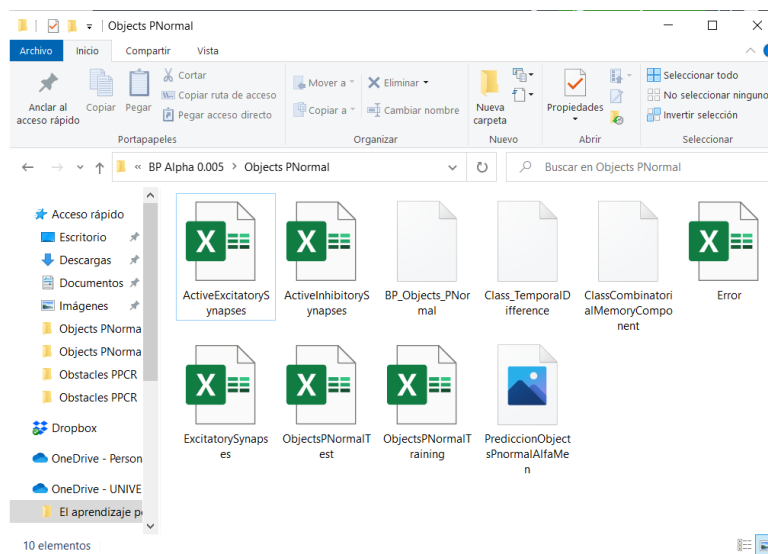
Figura A.11: Parte del archivo “Clasificación Comportamiento Estable”.

Por ultimo el contenido de las carpetas **BP Alpha 0.005** y **BP Alpha 0.85535** son cuatro carpetas correspondientes a los resultados de cada uno de los problemas, es decir para el problema de dificultad al caminar y con tareas de motricidad fina para un individuo sano y uno que sufrió un paro cardiorrespiratorio.

El contenido de cada una de estas carpetas se muestra en la figura A.12, donde observamos que se tienen los archivos .py con los que fueron generados los resultados, archivos con extensión .xlsx correspondientes al error que fue optimizado, los elementos del componente de memoria combinatoria como lo son las conexiones excitatorias, las excitatorias activas y las inhibitorias activas y además se tienen los archivos que contienen los objetos u obstáculos para las etapas de entrenamiento y prueba respectivamente, finalmente se encuentra la gráfica donde se muestra la salida deseada y la predicción obtenida por la red neuronal al finalizar el entrenamiento.

## A. APÉNDICE

---



**Figura A.12:** Contenido de las carpetas “BP Alpha 0.005” y “BP Alpha 0.85535”.

## A.9. Resultados de RMCS para dificultad al caminar de individuo sano.


### PNormal Synaptic 10-90

Individuo = Normal

Neuronas excitatorias = 10 %


Neuronas inhibitorias = 90 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 10 % de las conexiones excitatorias y 90 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 14.39 %, en la figura A.13 se muestra el aprendizaje promedio en cada simulación, con esto fue que se calculó el aprendizaje promedio total, que es realmente bajo debido a que en la mayoría de los casos se tienen aprendizajes por debajo del 40 % .




**Figura A.13:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Obstacles\_10-90.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar claramente que los resultados no son favorables ya que la mayoría son **NA**, en la figura A.14 podemos verificar esta información donde más del 76 % de las simulaciones tuvieron un comportamiento donde no se aprendió nada.



**Figura A.14:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.10-90.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.15, se observa que lo máximo que se logró aprender fueron 2 respuestas correctas y esto solo sucedió en 20 simulaciones.



**Figura A.15:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.10-90.

En la figura A.16 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como todos se encuentran por debajo del 50 % lo que explica el aprendizaje promedio total tan bajo.

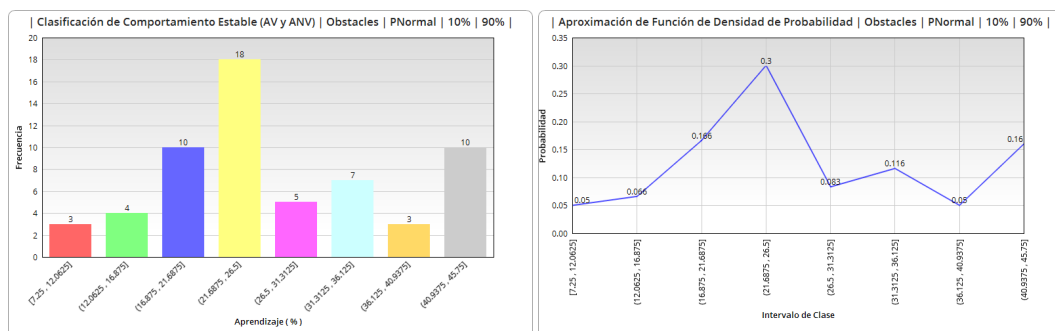
A.9 Resultados de RMCS para dificultad al caminar de individuo sano.



**Figura A.16:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal.Obstacles\_10-90.

Después de realizar la clasificación del comportamiento de aprendizaje, se realizó un histograma de frecuencias del aprendizaje obtenido en las simulaciones que fueron clasificadas como AV y ANV, es decir únicamente de los comportamientos estables, además con éste se obtuvo la función de densidad de probabilidad, los resultados obtenidos se muestran en la figura A.17.

Vemos que los aprendizajes a pesar de ser estables son bajos lo que nos indica que el tiempo de aprendizaje es corto, es decir logra aprender poco tiempo antes de terminar la etapa de entrenamiento o inicia con un comportamiento inestable y en las últimas 25 presentaciones del tiempo de aprendizaje se estabiliza, además que el total de respuestas correctas es bajo.



**Figura A.17:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal.Obstacles\_10-90.

No se conoce la función de probabilidad con exactitud, sin embargo, observamos

una curva multimodal donde de acuerdo a la aproximación de la función de densidad de probabilidad se tiene un 30 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones excitatorias - inhibitorias se obtengan comportamientos estables con un aprendizaje promedio entre 21.68 % y 26.5 %. Además de no ser una probabilidad alta, el aprendizaje promedio sería muy bajo, por lo que no se esperarían resultados satisfactorios a futuro, ya que de acuerdo a ese aprendizaje promedio esperado se tendrían muy pocas respuestas correctas.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 10 % de sus conexiones son excitatorias y 90 % inhibitorias, tenemos que con esta relación del 10 % - 90 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio total muy bajo y en los casos en que se observa aceptable, es decir es un aprendizaje que se mantiene estable durante el mayor tiempo de aprendizaje, solo se llegan a tener como máximo dos respuestas correctas lo que corresponde al 50 % del total de respuestas correctas esperadas.


Obteniendo una aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación (figuras A.14, A.15 y A.16), observamos que se tiene una curva en forma de J invertida, la cual corresponde a una función decreciente que nos indica que las probabilidades de tener aprendizajes altos es cada vez menor.

Por lo tanto, hablando a nivel biológico un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 10 % son excitatorias y el 90 % restante son inhibitorias, no tendría un desempeño favorable al realizar la actividad de caminar presentándole varios obstáculos.

### PNormal Synaptic 20-80


Individuo = Normal  
Neuronas excitatorias = 20 %  
Neuronas inhibitorias = 80 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 20% de las conexiones excitatorias y 80% inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 45.65%, en la figura A.18 se muestra el aprendizaje promedio en cada simulación, que es bajo pero mejor que el del caso anterior.




**Figura A.18:** Gráfica del aprendizaje promedio para cada simulación de PNormal.Obstacles\_20-80.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar claramente que los resultados no son favorables ya que la mayoría son **NA**, en la figura A.19 podemos verificar esta información donde casi el 63% de las simulaciones tuvieron un comportamiento en el que no se logra aprender nada.



**Figura A.19:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles\_20-80.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.20, se observa que existieron 10 casos en que si logra aprender las 4 respuestas correctas, sin embargo, en la mayoría de los casos no aprendió nada.



**Figura A.20:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles\_20-80.

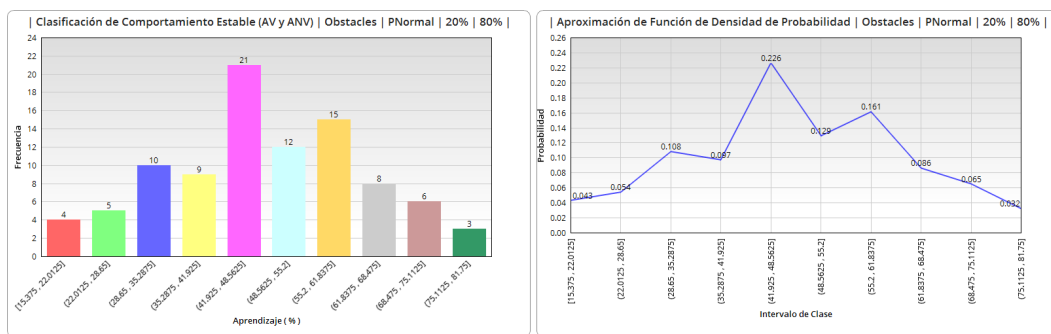
En la figura A.21, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 25 % al 68.75 %.

A.9 Resultados de RMCS para dificultad al caminar de individuo sano.



**Figura A.21:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Obstacles\_20-80.

En la figura A.22, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Vemos que los aprendizajes son bajos, pero un poco mayores que el caso anterior, al observar cada una de las gráficas de aprendizaje observamos que en la mayoría de los casos se tienen comportamientos que inician con fluctuaciones y al final se logra estabilizar manteniendo esa estabilidad por un periodo de tiempo corto.



**Figura A.22:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Obstacles\_20-80.

Al transformar a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva multimodal nuevamente, pero con una tendencia a ser una distribución gaussiana, sin embargo, de acuerdo a la aproximación de la función de densidad de probabilidad se tiene un

22.6% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 41.92% y 48.56%, con éste aprendizaje se esperaría un nivel de respuestas correctas aún bajo.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 20% de sus conexiones son excitatorias y 80% inhibitorias, tenemos que con esta relación del 20% - 80% en conexiones excitatorias - inhibitorias tampoco obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio bajo, fueron muy pocos los casos en que logró aprender las 4 respuestas correctas y en general en todas las simulaciones se tuvieron comportamientos con muchas fluctuaciones, lo que significa que aprendía y después de un tiempo corto ya no.


Además, si obtenemos una aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos que en la figura A.19 se tiene una curva en forma de J invertida, es decir una función decreciente que nos indica que la probabilidad de tener comportamientos en los que no se aprende nada es siempre mayor a poder tener comportamientos estables. En la figura A.20 observamos una curva multimodal donde se espera que la probabilidad mayor sea la de no tener ninguna respuesta correcta, lo que corresponde a los aprendizajes en los que no se logra aprender nada. Para los aprendizajes estables el máximo de respuestas correctas esperadas sería de 3 y en la figura A.21 se muestra una curva con tendencia a una distribución normal donde la probabilidad mayor se ubica al obtener los aprendizajes entre 43.75% y 50% lo que nos daría un nivel de respuestas correctas aún bajo.

Por lo tanto, hablando a nivel biológico un individuo que genere conexiones sinápticas con las características de esta red neuronal, donde un 20% son excitatorias y el 80% restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de caminar de manera normal al presentarle varios obstáculos ya que en ciertos momentos sabría como responder y al momento siguiente ya no, lo que en la vida real solo le sucede a las personas con serios problemas de memoria a corto o muy corto plazo.

### PNormal Synaptic 30-70


Individuo = Normal  
Neuronas excitatorias = 30 %  
Neuronas inhibitorias = 70 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 30% de las conexiones excitatorias y 70% inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 52.38%, en la figura A.23 se muestra el aprendizaje promedio en cada simulación, que sigue siendo bajo pero un poco mejor que los dos anteriores.




**Figura A.23:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Obstacles\_30-70.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar claramente que a pesar de tener un aprendizaje promedio bajo, los resultados de clasificación del comportamiento de aprendizaje son favorables ya que la mayoría son **AV**, en la figura A.24 podemos verificar esta información donde solo el 30% de los casos fueron en los que no se logró aprender nada.



**Figura A.24:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.30-70.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.25, se observa que de las 174 simulaciones que tuvieron un comportamiento estable, en 73 de ellas se logró aprender 3 respuestas correctas y en 25 las 4 respuestas correctas.



**Figura A.25:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.30-70.

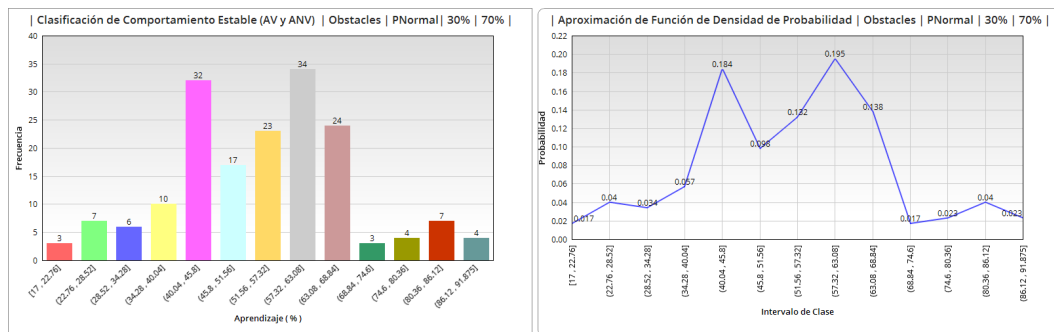
En la figura A.26, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 31.25% al 68.75%.

A.9 Resultados de RMCS para dificultad al caminar de individuo sano.



**Figura A.26:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal.Obstacles.30-70.

En la figura A.27, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. La mayoría de los aprendizajes se encuentran entre el 40.04% al 68.84%, lo que nos indica que el tiempo de aprendizaje comienza a ser mayor, además al analizar las gráficas de aprendizaje en cada simulación vemos que en la mayoría de los casos se inicia con un comportamiento con fluctuaciones entre 2 y 3 respuestas correctas y alcanza la estabilidad poco tiempo antes de terminar el tiempo de entrenamiento.



**Figura A.27:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal.Obstacles.30-70.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva bimodal, de acuerdo a la aproximación de la función de densidad de probabilidad se tiene un

## A. APÉNDICE

---

19.5 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 57.32 % y 63.08 %, aprendizajes mayores respecto a los casos anteriores. Con ese aprendizaje se esperaría un nivel de respuestas correctas mejor que en los casos anteriores.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 30 % de sus conexiones son excitatorias y 70 % inhibitorias, tenemos que con ésta relación del 30 % - 70 % en conexiones excitatorias - inhibitorias comenzamos a tener un mayor de número de casos con comportamientos estables, sin embargo, no son los suficientes casos en los que logra aprender las 4 respuestas correctas para decir que en general se tenga un aprendizaje bueno.

Además, si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.24 que la probabilidad mayor sería de obtener aprendizajes válidos, en la figura A.25 se tendría una curva multimodal en la cual los puntos máximos están al obtener 0 y 3 respuestas correctas, y en la figura A.26 se observa una curva suave que no logra ser una gaussiana pero se tendría la mayor probabilidad de obtener aprendizajes entre el 56.25 % y 62.5 %, que son mejores que en los casos anteriores al igual que el nivel de respuestas correctas.

Por lo tanto, hablando a nivel biológico un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 30 % son excitatorias y el 70 % restante son inhibitorias, no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que a pesar de tener un número mayor de simulaciones con comportamientos estables en comparación de los casos anteriores, esa estabilidad se mantiene por muy poco tiempo al final del aprendizaje al igual que lo hace en los casos anteriores, a excepción de ciertos casos en que tenemos un aprendizaje mayor a 91 % ya que no sólo logra aprender las cuatro respuestas correctas sino que lo hace rápidamente.


### PNormal Synaptic 40-60

Individuo = Normal

Neuronas excitatorias = 40 %

Neuronas inhibitorias = 60 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 40 % de las conexiones excitatorias y 60 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 50.76 %, en la figura A.28 se muestra el aprendizaje promedio en cada simulación, que sigue siendo bajo, mejor que los dos primeros pero un poco más bajo que el anterior.




**Figura A.28:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Obstacles\_40-60.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar que los resultados no son tan malos ya que la mayoría son **AV**, en la figura A.29 podemos verificar esta información donde solo el 34 % de los casos aproximadamente fueron en los que no se logra aprender nada.


## A. APÉNDICE

---



**Figura A.29:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles\_40-60.

Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.30, se observa que de las 166 simulaciones que tuvieron un comportamiento estable, la mayoría se encuentra entre 2 o 3 respuestas correctas, solo en 20 simulaciones se lograron aprender las 4 respuestas correctas.




**Figura A.30:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles\_40-60.

En la figura A.31 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra


## A.9 Resultados de RMCS para dificultad al caminar de individuo sano.

entre el 37.5 % al 68.75 %.



**Figura A.31:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Obstacles\_40-60.

En la figura A.32 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. En este caso comenzamos a ver aprendizajes mayores al 41.65 % y al analizar las gráficas del aprendizaje, observamos que se tienen más simulaciones donde el aprendizaje se mantiene estable durante una mayor parte del tiempo de entrenamiento a diferencia de los casos anteriores en que se tenían fluctuaciones las mayor parte del tiempo y la estabilidad solo se daba al final del aprendizaje pero por un periodo corto de tiempo.



**Figura A.32:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Obstacles\_40-60.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva bimodal,

donde de acuerdo a la aproximación de la función de densidad de probabilidad se tienen dos puntos máximos. En el primero se tiene un 21.7% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 41.65% y 47%. En el segundo se tiene un 21.1% de probabilidad de obtener aprendizajes promedio entre 63.05% y 68.4%. Por lo tanto, en el primer caso se incluirían los comportamientos en los que solo logra aprender como máximo 2 respuestas correctas y en el segundo caso estarán incluidos los comportamientos donde se aprenden 3 respuestas correctas.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 40% de sus conexiones son excitatorias y 60% inhibitorias, tenemos que con esta relación del 40%-60% en conexiones excitatorias - inhibitorias, se obtienen peores resultados que en el caso anterior respecto a que se tuvieron más casos en los que no logró aprender nada, sin embargo en los casos en que se tienen comportamientos de aprendizaje estables, la estabilidad se mantiene durante un mayor tiempo que en los casos anteriores.


Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.29 una curva suave con tendencia a ser una gaussiana, donde la mayor probabilidad sería obtener aprendizajes válidos. En la figura A.30 tenemos una curva bimodal en la que los puntos máximos se encuentran en obtener 0 o 3 respuestas correctas y en la figura A.31 nuevamente se tiene una curva que pareciera ser una gaussiana. Sin embargo, se tienen variaciones que la convierten en una curva bimodal, donde las mayores probabilidades están en obtener aprendizajes promedio entre 43.75% y 50% o 62.5% y 68.75%, lo que nos lleva a concluir de acuerdo a la interpretación de la aproximación de la función de densidad de probabilidad de las frecuencias en los aprendizajes con comportamiento estable mencionada anteriormente, que en el primer intervalo se encuentran los comportamientos con 2 respuestas correctas y en el segundo intervalo los que aprenden 3.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que el número total de simulaciones en las que no se aprendió nada es alto y fueron menos las simulaciones en las que se logró aprender las 4 respuestas correctas respecto a las del caso anterior.

### PNormal Synaptic 50-50


Individuo = Normal  
Neuronas excitatorias = 50 %  
Neuronas inhibitorias = 50 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 50 % de las conexiones excitatorias y 50 % inhibitorias, se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 41.99 %, en la figura A.33 se muestra el aprendizaje promedio en cada simulación, que es aún más bajo que en el caso anterior.




**Figura A.33:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Obstacles\_50-50.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar que los resultados no son favorables ya que la mayoría son **NA**, en la figura A.34 podemos verificar esta información, teniendo 91 simulaciones en las que no se logra aprender nada.



**Figura A.34:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.50-50.

Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.35, se observa que de las 160 simulaciones que tuvieron un comportamiento estable, la mayoría aprendió solo 2 respuestas correctas, en 43 simulaciones se tuvieron 3 y solo en 17 simulaciones se aprendieron las 4.




**Figura A.35:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.50-50.

En la figura A.36, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra


A.9 Resultados de RMCS para dificultad al caminar de individuo sano.

entre el 18.75 % al 68.75 % que son aprendizajes bajos y se explica porque sólo alcanzó aprender 2 respuestas correctas como máximo.



**Figura A.36:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal.Obstacles\_50-50.

En la figura A.37, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Vemos que los aprendizajes son bajos y al analizar las gráficas, observamos que se siguen teniendo muchos casos con comportamientos que inician fluctuando y poco tiempo antes de terminar el tiempo de entrenamiento se estabilizan.



**Figura A.37:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal.Obstacles\_50-50.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva multimodal, donde de acuerdo a la aproximación de la función de densidad de probabilidad se

tiene un 13.1 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 21.28 % y 26.70 % y un 15 % de probabilidad de que estén entre 42.94 % y 48.35 %, por lo que concluimos que en el primer intervalo se incluyen las simulaciones en las que se aprendió solo 1 respuesta correcta y en el segundo intervalo las que lograron aprender 2.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 50 % de sus conexiones son excitatorias y 50 % inhibitorias, tenemos que con esta relación del 50 %-50 % en conexiones excitatorias - inhibitorias se obtienen resultados aún más bajos que en los casos anteriores, ya que se tiene un aprendizaje promedio más bajo y un total de simulaciones con aprendizajes no válidos mayor en comparación con los dos casos anteriores.

Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.34 una curva con forma de J invertida, es decir una función decreciente que nos indica que la probabilidad mayor está en obtener comportamientos de aprendizaje en los que no se logra aprender nada. En la figura A.35 tenemos una curva multimodal, donde los puntos máximos de probabilidad están al obtener 0 respuestas correctas, correspondientes a los comportamientos en que no aprende nada, o 2 que ya pertenecen a los comportamientos estables, sin embargo, la probabilidad es mayor para las 0 respuestas correctas como ya vimos en la figura anterior. Por último en la figura A.36, observamos una curva multimodal en la que los puntos máximos de probabilidad se encuentran en los intervalos de 18.75 % a 25 % y de 37.5 % a 43.75 % que los dos son muy bajos y por lo tanto, el nivel de respuestas correctas que se esperarían sería bajo.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 50 % son excitatorias y el 50 % restante son inhibitorias, no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que en la mayoría el aprendizaje promedio está por debajo del 60 % o sea es bajo y son muy pocos los casos en que se logran aprender las 4 respuestas correctas.


### PNormal Synaptic 60-40

Individuo = Normal

Neuronas excitatorias = 60 %

Neuronas inhibitorias = 40 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 60 % de las conexiones excitatorias y 40 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 38.54 %, en la figura A.38 se muestra el aprendizaje promedio en cada simulación, aún más bajo que en los cuatro casos anteriores.




**Figura A.38:** Gráfica del aprendizaje promedio para cada simulación de PNormal.Obstacles\_60-40.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar que los resultados son favorables ya que a pesar de tener un aprendizaje promedio tan bajo, la mayoría de las simulaciones son **AV** y **ANV**, en la figura A.39 podemos verificar esta información, teniendo solo el 20 % de los casos en que no se logra aprender nada.


## A. APÉNDICE

---



**Figura A.39:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.60-40.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.40, se observa que en la mayoría de los casos se lograron aprender 2 o 3 respuestas correctas y en solo 8 simulaciones se tuvieron las 4 respuestas correctas.



**Figura A.40:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.60-40.


En la figura A.41, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra por debajo del 50% que son aprendizajes bajos aún.

A.9 Resultados de RMCS para dificultad al caminar de individuo sano.



**Figura A.41:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal.Obstacles.60-40.

En la figura A.42, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Observamos que los aprendizajes siguen siendo bajos, sin embargo, se tienen aprendizajes que se comportan estables casi desde un principio del tiempo de aprendizaje, pero como ya vimos con solo 2 o 3 respuestas correctas.



**Figura A.42:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal.Obstacles.60-40.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal, donde de acuerdo a la aproximación de la función de densidad de probabilidad se tiene un 14.4% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con

un aprendizaje promedio entre 18.83 % y 24.10 % y un 15.9 % de probabilidad de que estén entre 39.93 % y 45.21 %, que son aprendizajes muy bajos, aún más que en el caso anterior, sin embargo, los resultados respecto a la clasificación de los comportamientos de aprendizaje y las respuestas correctas son mejores para este caso.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 60 % de sus conexiones son excitatorias y 40 % inhibitorias, tenemos que con esta relación del 60 %-40 % en conexiones excitatorias - inhibitorias se obtienen resultados no favorables desde el punto de vista que se tiene un aprendizaje promedio bajo en comparación con los casos anteriores, sin embargo, tenemos más simulaciones en que si logra aprender pero en la mayoría solo se aprenden 2 o 3 respuestas correctas.

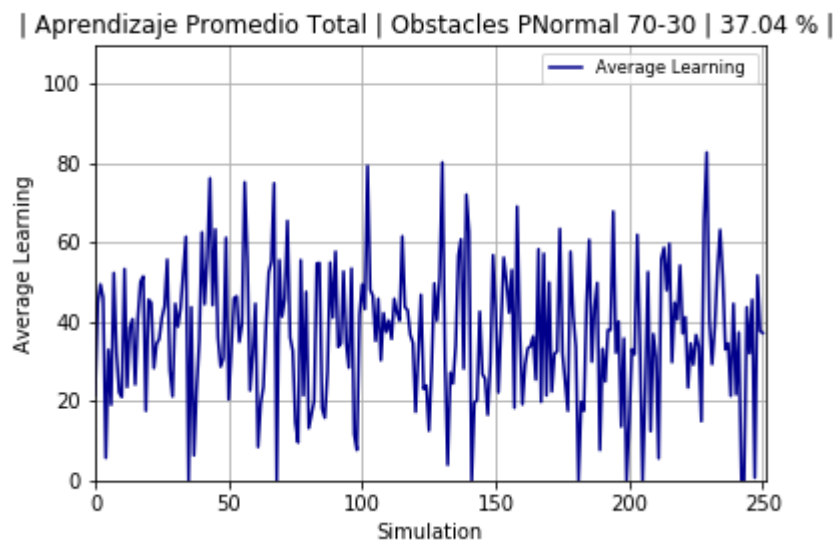
Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.39 una curva suave con tendencia a ser una gaussiana, lo que es muy bueno ya que la probabilidad mayor es para los aprendizajes clasificados como válidos. En la figura A.40 tenemos una curva multimodal donde los puntos máximos de probabilidad están al obtener 2 o 3 respuestas correctas, que es mejor que los casos anteriores, ya que notamos que el total de simulaciones en las que no logra aprender comienza a disminuir y en consecuencia tenemos más aprendizajes con comportamiento estable, aunque aún con un nivel de respuestas correctas un poco bajo. Por último en la figura A.41 observamos una curva que estuvo cerca de conseguir la simetría, sin embargo tenemos algunos puntos máximos de probabilidad que se encuentran en los intervalos de 18.75 % a 25 % de 31.25 % a 37.5 % y de 43.75 % a 50 %, los tres son bastante bajos, sin embargo, en ellos se tienen 1, 2 y 3 respuestas correctas. A pesar de ser bajos se llegan a obtener 3 respuestas correctas, esto se debe a que las fluctuaciones que se tenían en los casos anteriores han ido disminuyendo y la estabilidad en el aprendizaje se conserva de inicio a fin por más del 80 % del total del tiempo de aprendizaje, por lo tanto, aunque sea bajo el aprendizaje promedio ahora si comienza a tener mejor nivel de respuesta.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 60 % son excitatorias y el 40 % restante son inhibitorias, no tendrá un desempeño tan favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que los casos en que logra aprender las 4 respuestas correctas son muy pocos, sin embargo, comenzamos a tener comportamientos que se comportan estables por un tiempo de aprendizaje mayor en comparación a los casos anteriores.

### PNormal Synaptic 70-30

Individuo = Normal  
Neuronas excitatorias = 70 %  
Neuronas inhibitorias = 30 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 70% de las conexiones excitatorias y 30% inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 37.04%, en la figura A.43 se muestra el aprendizaje promedio en cada simulación, que es más bajo que en el caso anterior.




**Figura A.43:** Gráfica del aprendizaje promedio para cada simulación de PNormal.Obstacles\_70-30.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar que los resultados son favorables ya que a pesar de tener un aprendizaje promedio tan bajo la mayoría de las simulaciones son consideradas **AV** y **ANV**. En la figura A.44 podemos verificar esta información, teniendo solo el 14% de los casos en que no se logra aprender nada.


## A. APÉNDICE

---



**Figura A.44:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.70-30.

Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.45, se observa notablemente que de las 214 simulaciones en que se obtuvo un comportamiento estable la mayoría logró aprender solo 2 respuestas correctas y en solo 14 simulaciones se aprendieron las 4.



**Figura A.45:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.70-30.

En la figura A.46, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra por debajo del 56.25 % que son aprendizajes bajos.

A.9 Resultados de RMCS para dificultad al caminar de individuo sano.




Figura A.46: Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal.Obstacles\_70-30.

En la figura A.47, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Al analizar las gráficas de aprendizaje, observamos que la estabilidad permanece por más de la mitad del tiempo total de aprendizaje, sin embargo, se tienen aprendizajes bajos porque el total de respuestas correctas que logra aprender es muy bajo.




Figura A.47: Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal.Obstacles\_70-30.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal nuevamente, de acuerdo a la aproximación de la función de densidad de probabilidad se tiene un 13.6% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 31.33% y 36.47% o entre 41.61% y 46.76%, que son

aprendizajes bajos. Sin embargo, el nivel de respuestas correctas obtenido en ellos no es tan malo por que al menos se logran aprender 2 o 3 respuestas correctas al igual que en el caso anterior.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 70 % de sus conexiones son excitatorias y 30 % inhibitorias, tenemos que con la relación del 70 %-30 % en conexiones excitatorias - inhibitorias se obtienen resultados menos satisfactorios hablando del aprendizaje promedio porque es aún más bajo que en los casos anteriores, sin embargo, los comportamientos son mejores pero el nivel de respuesta es aún bajo.


Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.44 una curva suave con tendencia a ser una función creciente, lo que es muy bueno ya que la probabilidad mayor es para los aprendizajes clasificados como válidos y el total de aprendizajes en los que no aprendió nada es cada vez menor. En la figura A.45 tenemos una curva que casi logra ser simétrica donde la probabilidad máxima es para obtener 2 respuestas correctas en las simulaciones. Por último en la figura A.46, observamos una curva suave sesgada un poco a la derecha, es decir los aprendizajes promedio son bajos, sin embargo, tenemos algunos puntos máximos de probabilidad en intervalos de aprendizaje bastante bajos y en ellos no solo se incluyen los aprendizajes estables sino también los que no lograron aprender nada, ya que al tener un comportamiento con tantas fluctuaciones lo hace acumular respuestas correctas y así obtener un aprendizaje promedio alto. Para este caso las simulaciones que tienen fluctuaciones son únicamente las que fueron clasificadas como “no aprendió”, en las demás el comportamiento estable se mantiene desde un inicio, así que aunque sigan siendo los aprendizajes promedio muy bajos al igual que el nivel de respuestas correctas notamos como los comportamientos van mejorando, lo que corresponde a la memoria, es decir, una vez que aprende algo ya no lo olvida, cosa que no se había presentado con tanta frecuencia en los casos anteriores.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 70 % son excitatorias y el 30 % restante son inhibitorias, no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que en la mayoría el aprendizaje está por debajo del 50 %, ya que la mayoría sólo logra aprender 2 respuestas correctas, o sea es bajo y en muy pocos casos se logran aprender las 4, sin embargo, comienza a presentar señales de tener buena memoria.

### PNormal Synaptic 80-20


Individuo = Normal  
Neuronas excitatorias = 80 %  
Neuronas inhibitorias = 20 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 80 % de las conexiones excitatorias y 20 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 35.76 %, en la figura A.48 se muestra el aprendizaje promedio en cada simulación, que es todavía más bajo que en el caso anterior.




**Figura A.48:** Gráfica del aprendizaje promedio para cada simulación de PNormal.Obstacles\_80-20.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar que los resultados son favorables, ya que a pesar de tener un aprendizaje promedio tan bajo la mayoría de las simulaciones presentaron comportamientos **AV** y **ANV**, en la figura A.49 podemos verificar esta información, teniendo solo el 12 % de los casos en que no se logra aprender nada.



**Figura A.49:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.80-20.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.50, se observa notablemente que de las 220 simulaciones en que se obtuvo un comportamiento estable la mayoría logró aprender solo 2 o 3 respuestas correctas y en solo 10 simulaciones las 4.



**Figura A.50:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.80-20.


En la figura A.51, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra

por debajo del 56.25 % que son aprendizajes bajos.



**Figura A.51:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal.Obstacles\_80-20.

En la figura A.52, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. La mayoría se encuentra entre 18.05 % a 56.875 %, observando el comportamiento de las gráficas de aprendizaje notamos que son estables la mayor parte del tiempo de aprendizaje, aunque con pocas respuestas correctas aprendidas aún.



**Figura A.52:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal.Obstacles.80-20.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal una vez más, de acuerdo a la aproximación de la función de densidad de probabilidad

se tiene un 13.6% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 32.62% y 37.47%, que son aprendizajes bajos, sin embargo, el nivel de respuestas correctas obtenido no es tan malo ya que al menos se logran aprender 2 respuestas correctas al igual que en el caso anterior.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 80% de sus conexiones son excitatorias y 20% inhibitorias, tenemos que con esta relación del 80%-20% en conexiones excitatorias - inhibitorias se obtiene un aprendizaje promedio aún más bajo que en el caso 70%-30%, pero una vez más el casos de comportamientos en que no logra aprender es menor y en consecuencia se tienen más casos en que logra aprender.


Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación observamos en la figura A.49 una curva suave con tendencia a ser una función creciente, nuevamente la probabilidad mayor es para los aprendizajes clasificados como válidos y el total de aprendizajes en los que no aprendió nada es cada vez menor en comparación a los casos anteriores. En la figura A.50 tenemos una curva suave un poco sesgada a la izquierda, donde la probabilidad máxima es para obtener 2 o 3 respuestas correctas en las simulaciones y por último en la figura A.51 observamos una curva no tan suave sesgada un poco a la derecha, es decir, los aprendizajes promedio son bajos, es muy parecida a la del caso anterior, con el cambio de que se tiene una mayor frecuencia en aprendizaje que se encuentran entre 50% y 56.56% debido a que se tienen más comportamientos estables. Para este caso también las simulaciones que tienen fluctuaciones son únicamente las que fueron clasificadas como “no aprendió”, en las demás el comportamiento estable se mantiene desde un inicio, así que aunque sigan siendo los aprendizajes promedio muy bajos al igual que el nivel de respuestas correctas, al alcanzar máximo 2 o 3 notamos como los comportamientos van mejorando que nuevamente asociamos a la memoria del individuo, es decir una vez que aprende algo ya no lo olvida.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 80% son excitatorias y el 20% restante son inhibitorias, no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que a lo mucho sabría responder solo a dos o tres de los obstáculos presentados en la mayoría de los casos, sin embargo, el nivel de memoria es cada vez mejor, al retener la información aprendida desde un inicio del aprendizaje e ir aumentando el conocimiento.

### PNormal Synaptic 90-10


Individuo = Normal  
Neuronas excitatorias = 90 %  
Neuronas inhibitorias = 10 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 90 % de las conexiones excitatorias y 10 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 36.76 %, en la figura A.53 se muestra el aprendizaje promedio en cada simulación, un poco mayor al del caso anterior pero aún bajo en comparación de los anteriores.




**Figura A.53:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Obstacles\_90-10.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar que los resultados son favorables, ya que a pesar de tener un aprendizaje promedio tan bajo la mayoría de las simulaciones tienen comportamientos **ANV** y **AV**, en la figura A.54 podemos verificar esta información, teniendo solo el 7 % de los casos en que no se logra aprender nada.



**Figura A.54:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.90-10.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.55, se observa notablemente que de las 213 simulaciones en que se obtuvo un comportamiento estable la mayoría logró aprender solo 1, 2 o 3 respuestas correctas.



**Figura A.55:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.90-10.

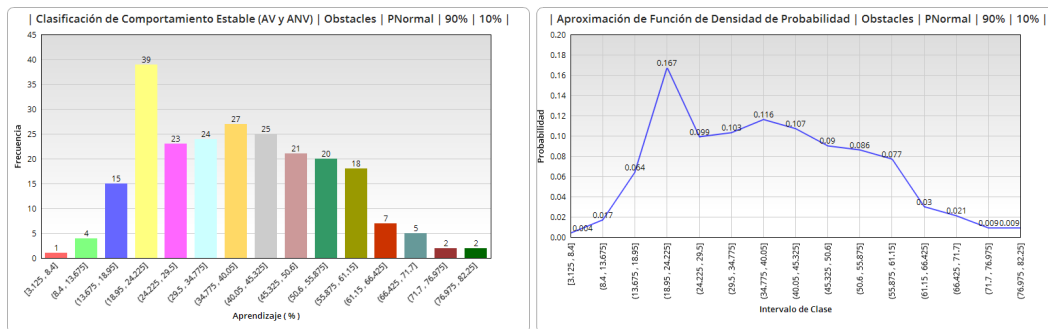
En la figura A.56, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra por debajo del 62.5% que son aprendizajes bajos.

A.9 Resultados de RMCS para dificultad al caminar de individuo sano.



**Figura A.56:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal.Obstacles\_90-10.

En la figura A.57, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Al igual que en el caso anterior los aprendizajes son bajos pero el comportamiento se mantiene estable, en comparación con los casos anteriores éste lo hace por un tiempo de aprendizaje menor ya que en la mayoría de las simulaciones comienza aprender cerca de la mitad del tiempo total del aprendizaje y se sigue teniendo un total de respuestas correctas bajo.



**Figura A.57:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal.Obstacles\_90-10.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva bimodal con tendencia a una función decreciente. De acuerdo a la aproximación de la función de densidad de probabilidad se tiene un 16.7% de probabilidad de que al realizar más

simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 18.95 % y 24.22 %, que son aprendizajes bajos, y es donde están incluidos los casos en que logra aprender solo 1 respuesta correcta y en algunos casos 2, pero que comienzan su aprendizaje cerca de la mitad del tiempo total de aprendizaje.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 90 % de sus conexiones son excitatorias y 10 % inhibitorias, tenemos que con esta relación del 90 %-10 % en conexiones excitatorias - inhibitorias se obtiene un aprendizaje promedio bajo y se tienen más simulaciones con comportamientos estables, es decir, donde si logra aprender.


Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.54 una curva suave con tendencia a ser una función creciente, donde la probabilidad mayor es para las simulaciones con comportamientos estables pero con aprendizaje promedio muy bajo, y nuevamente el total de aprendizajes en los que no aprendió nada es cada vez menor en comparación a los casos anteriores. En la figura A.55 tenemos una curva suave con tendencia a ser una gaussiana, donde la probabilidad máxima es para obtener 2 respuestas correctas en las simulaciones. Por último en la figura A.56 observamos una curva bimodal también con tendencia a una gaussiana con la excepción de un punto máximo de probabilidad en el intervalo de 18.75 % a 25 % donde están incluidos los aprendizajes con comportamiento estable ya mencionados anteriormente. Para este caso también las simulaciones que tienen fluctuaciones son únicamente las que fueron clasificadas como “no aprendió”, en las demás el comportamiento estable se mantiene desde un inicio, con la excepción de que ahora las simulaciones en que se aprenden 1 y 2 respuestas correctas, que por cierto es mayor a las del caso anterior, logran aprender en un tiempo de aprendizaje de aproximadamente la mitad del tiempo total o menos, por eso es que se tienen aprendizajes tan bajos, además es importante mencionar que se sigue conservando la memoria al no olvidar lo ya aprendido en la mayoría de los casos.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 90 % son excitatorias y el 10 % restante son inhibitorias, no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que a lo mucho sabría responder solo a 2 o 3 de los obstáculos presentados en la mayoría de los casos y además en algunos casos su aprendizaje se comienza a dar después de mucho tiempo de iniciar la etapa de aprendizaje, es decir, se tarda más en aprender en comparación al caso anterior pero sigue conservando la característica de memoria.

### PNormal Synaptic 100-0


Individuo = Normal  
Neuronas excitatorias = 100 %  
Neuronas inhibitorias = 0 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 100 % de las conexiones excitatorias y 0% inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 57.87 %, en la figura A.58 se muestra el aprendizaje promedio en cada simulación, con esto fue que se calculó el aprendizaje promedio total, que es bajo pero es el mejor respecto a los casos anteriores.




**Figura A.58:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Obstacles\_100-0.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar que los resultados son favorables ya que a pesar de tener un aprendizaje promedio tan bajo la mayoría de las simulaciones presentan comportamientos **AV** y **ANV**, en la figura A.59 podemos verificar esta información, teniendo solo el 4 % de los casos en que no se logra aprender nada.



**Figura A.59:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.100-0.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.60, se observa notablemente que de las 239 simulaciones en que se obtuvo un comportamiento estable la mayoría logró aprender sólo 3 respuestas correctas, en solo 41 simulaciones se obtuvieron las 4.



**Figura A.60:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Obstacles.100-0.

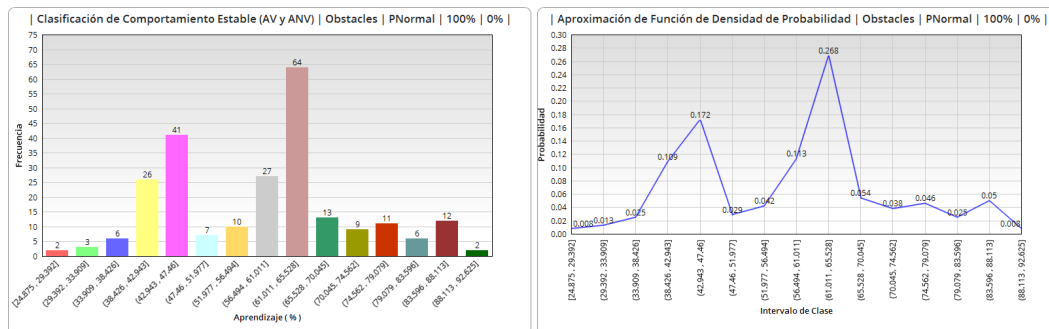
En la figura A.61, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre 37.5% y 68.75%, que no son aprendizajes altos pero si mejores que los obtenidos

en casos anteriores.



**Figura A.61:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Obstacles\_100-0.

En la figura A.62, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Los aprendizajes son un poco mayores que en los casos anteriores ya que los comportamientos se mantienen estables la mayor parte del tiempo pero aprendiendo sólo 3 respuestas correctas en la mayoría de las simulaciones.



**Figura A.62:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Obstacles\_100-0.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva bimodal, muy parecida a la de los casos 30 % excitatorias - 70 % inhibitorias y 40 % excitatorias - 60 % inhibitorias pero donde los puntos máximos de probabilidad incluyen intervalos

de aprendizaje más altos que en esos casos, de acuerdo a la aproximación de la función de densidad de probabilidad se tiene un 26.8% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 61.01% y 65.52%, que son aprendizajes mucho mayores a los de los casos anteriores, ya que ahora tenemos un nivel de respuestas correctas más alto.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 100% de sus conexiones son excitatorias y 0% inhibitorias, tenemos que con la relación del 100%-0% en conexiones excitatorias - inhibitorias se obtienen resultados satisfactorios de acuerdo a que obtuvimos un aprendizaje más alto que en los casos anteriores, el total de simulaciones que se consideran como aprendizajes válidos es cada vez más alto, es decir, los comportamientos son mejores pero el nivel de respuesta es aún bajo al tener muy pocos casos con las 4 respuestas correctas aprendidas.

Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.59 una curva suave sesgada a la izquierda, donde la probabilidad mayor es para las simulaciones con comportamientos de aprendizaje válidos, y nuevamente el total de aprendizajes en los que no aprendió nada es cada vez menor en comparación a los casos anteriores. En la figura A.60 tenemos una curva suave también sesgada a la izquierda, donde la probabilidad máxima es para obtener 3 respuestas correctas en las simulaciones. Por último en la figura A.61 observamos una curva bimodal, donde los puntos máximos de probabilidad son para los intervalos con aprendizaje mayor al 50%, mayor a los casos anteriores debido a que ahora el nivel de respuestas correctas es mayor, al tener 3 respuestas correctas en la mayoría de las simulaciones. Para este caso al igual que en los dos anteriores, las simulaciones que tienen fluctuaciones son únicamente las que fueron clasificadas como “no aprendió”, en las demás el comportamiento estable se mantiene desde un inicio y el aprendizaje se da con más rapidez que en cualquiera de los casos anteriores y sobre todo se sigue conservando la memoria al no olvidar lo ya aprendido.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que en la mayoría sólo logra aprender 3 respuestas correctas. Cabe mencionar que además de manera biológica es poco probable que se pueda realizar este tipo de conexión ya que las conexiones inhibitorias son también necesarias para bloquear o disminuir la actividad de algunas neuronas que resulta innecesaria para realizar de manera correcta cualquier actividad de la vida diaria.

## A.10. Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorespiratorio.


### PPCR Synaptic 10-90

Individuo = Paro Cardiorespiratorio

Neuronas excitatorias = 10 %


Neuronas inhibitorias = 90 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 10 % de las conexiones excitatorias y 90 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 7.76 %, en la figura A.63 se muestra el aprendizaje promedio en cada simulación, con esto fue que se calculó el aprendizaje promedio total, que es realmente bajo. Podemos notar que la mayoría de las simulaciones obtuvieron un aprendizaje promedio por debajo del 20 %.




**Figura A.63:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_10-90.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que la mayoría se encuentra en la clase **NA**. En la figura A.64 podemos verificar esta información, donde más del 90 % de las simulaciones tuvieron un comportamiento donde no se aprendió nada.



**Figura A.64:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.10-90.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.65, se observa que lo máximo que se logró aprender fue 1 respuesta correcta y esto sólo sucedió en 20 simulaciones.



**Figura A.65:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.10-90.

En la figura A.66, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como todos se encuentran por debajo del 50 % lo que explica el aprendizaje promedio total tan bajo.


A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.



**Figura A.66:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_10-90.

Después de realizar la clasificación del comportamiento de aprendizaje, se realizó un histograma de frecuencias del aprendizaje obtenido en las simulaciones que fueron clasificadas como AV y ANV, es decir, únicamente de los comportamientos estables, además la aproximación de la función de densidad de probabilidad de éste histograma. Los resultados obtenidos se muestran en la figura A.67.

Observamos que los aprendizajes son muy bajos y al analizar las gráficas de aprendizaje, observamos que el tiempo de aprendizaje es corto, es decir, logra aprender poco tiempo antes de terminar el entrenamiento o inicia con un comportamiento inestable y en las últimas 25 presentaciones del tiempo de aprendizaje se estabiliza.



**Figura A.67:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_10-90.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva suave pe-

ro decreciente la mayor parte del tiempo. Se tiene un 37.5 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 17.72 % y 27.57 %, que son aprendizajes demasiado bajos debido a que la mayoría de las simulaciones no aprendió nada.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 10 % de sus conexiones son excitatorias y 90 % inhibitorias, tenemos que con esta relación del 10 %-90 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio total demasiado bajo y en los casos en que el comportamiento se observa gráficamente aceptable, es decir, es un aprendizaje que se mantiene estable, sólo se llegan a tener como máximo 2 respuestas correctas, pero esto sucede sólo en 4 simulaciones.

Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, figuras A.64, A.65 y A.66, observamos que se trata de curvas con forma de J invertida, es decir, funciones decrecientes en las que la mayor probabilidad la tienen los aprendizajes no válidos en los que no se logra aprender nada.


Este comportamiento también se obtuvo para una persona sana con este mismo porcentaje de conexiones sinápticas, sin embargo, para la persona que sufrió un paro cardiorespiratorio se obtuvieron los resultados todavía menos satisfactorios.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 10 % son excitatorias y el 90 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos.

### PPCR Synaptic 20-80


Individuo = Paro Cardiorrespiratorio  
Neuronas excitatorias = 20 %  
Neuronas inhibitorias = 80 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio con 20 % de las conexiones excitatorias y 80 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 29.05 %, en la figura A.68 se muestra el aprendizaje promedio en cada simulación, es bajo pero mayor que en el caso anterior.




**Figura A.68:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_20-80.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que la mayoría se encuentra en **NA**. En la figura A.69 podemos verificar esta información donde más del 68 % de las simulaciones tuvieron un comportamiento donde no se aprendió nada.



**Figura A.69:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.20-80.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.70, se observa que lo máximo que se logró aprender fueron 3 respuesta correctas pero esto sólo sucedió en 3 simulaciones, en la mayoría de las simulaciones sólo se aprendió una respuesta correcta .




**Figura A.70:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.20-80.

En la figura A.71, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como todos se encuentran por debajo del


A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorespiratorio.

50 %, lo que explica el aprendizaje promedio total tan bajo.



**Figura A.71:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_20-80.

En la figura A.72, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Podemos ver que los aprendizajes son bajos, se tienen comportamientos que inician con fluctuaciones y la estabilidad la alcanza al final, durante poco tiempo del aprendizaje y además se logran aprender muy pocas respuestas correctas.



**Figura A.72:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_20-80.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva suave pero decreciente la mayor parte del tiempo al igual que el caso anterior, se tiene un 27.8 % de probabilidad de que al realizar más simulaciones con estas características

en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 22.38 % y 28.45 %, que son aprendizajes bajos pero mayores a los del caso anterior, de igual manera se tiene esto debido a que el número de simulaciones donde no se aprendió nada es mayor.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorrespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 20 % de sus conexiones son excitatorias y 80 % inhibitorias, tenemos que con esta relación del 20 %-80 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio total bajo y en los casos en que el comportamiento se observa gráficamente aceptable, es decir, es un aprendizaje que se mantiene estable, sólo se llegan a tener como máximo una o dos respuestas correctas, únicamente en tres casos obtuvimos 3 respuestas correctas.

Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.69 una curva con tendencia a tener forma de U, donde la probabilidad mayor es para los comportamientos de aprendizaje no válidos, es decir donde no logra aprender absolutamente nada. Para la figura A.70 tenemos una curva con forma de J invertida, es decir, una función decreciente en la que la probabilidad mayor es al obtener 0 respuestas correctas, que es algo esperado debido a la forma de la figura anterior. Finalmente en la figura A.71 se tiene una curva suave sesgada a la derecha, en la que la probabilidad mayor se da al obtener aprendizajes entre 25 % y 31.25 % que son considerados como muy bajos, pero es debido al bajo nivel de respuestas correctas que se logra obtener.


En comparación a los resultados de una persona sana, estos son más bajos, ya que para una persona sana se obtienen menos casos de aprendizaje no válidos y la mayor probabilidad es para aprendizajes que están entre 43.75 % y 50 %, por lo tanto logran aprender un poco más de respuestas correctas.

Por lo tanto, hablando a nivel biológico, un individuo con conexiones sinápticas con las características de esta red neuronal donde un 20 % son excitatorias y el 80 % restante son inhibitorias, tampoco tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos.

### PPCR Synaptic 30-70


Individuo = Paro Cardiorrespiratorio  
Neuronas excitatorias = 30 %  
Neuronas inhibitorias = 70 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio con 30 % de las conexiones excitatorias y 70 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 40.56 %, en la figura A.73 se muestra el aprendizaje promedio en cada simulación, que es bajo pero mejor que los dos anteriores.




**Figura A.73:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_30-70.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que la mayoría se encuentra en **NA**, sin embargo, el número de simulaciones en que logró aprender es mayor que en los dos casos anteriores. En la figura A.74 podemos verificar esta información donde 55 % de las simulaciones tuvieron un comportamiento estable.



**Figura A.74:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.30-70.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.75, se observa que en la mayoría de las simulaciones sólo se aprendieron 2 respuestas correctas y en solo cinco simulaciones se aprendieron las 4.



**Figura A.75:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.30-70.


En la figura A.76, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra entre el 18.75 % y 68.75 %, que se consideran aprendizajes bajos.

A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.



**Figura A.76:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_30-70.

En la figura A.77, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Notamos que la mayoría se encuentra entre el 38% al 44%, y todavía la mayoría de las simulaciones presentan comportamientos con fluctuaciones al inicio del aprendizaje como en los dos casos anteriores.



**Figura A.77:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_30-70.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal, donde se tiene un 24.3% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 38.54% y 44.33%, que son aprendizajes bajos pero mayores a los de los dos casos anteriores. Esto se debe a que el nivel de respuestas

correctas es aún bajo, aprendiendo solo 1 o 2.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 30 % de sus conexiones son excitatorias y 70 % inhibitorias, tenemos que con esta relación del 30 %-70 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje tan favorables, ya que en general se obtiene un aprendizaje promedio total bajo pero se tienen más casos en que el comportamiento se observa gráficamente estable respecto a los casos anteriores.

Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.74 una curva con forma de J invertida, es decir, decreciente, en la que la probabilidad mayor es para las simulaciones en las que no se logra aprender nada. Para la figura A.75 tenemos una curva multimodal, donde los puntos máximos de probabilidad son para obtener 0 o 2 respuestas correctas, aclarando que es mucho mayor la de 0 respuestas correctas debido a la tendencia de la gráfica anterior. Finalmente en la figura A.76 también se tiene una curva multimodal, donde el punto máximo de probabilidad es al obtener aprendizajes que se encuentran en el intervalo de 37.5 % a 43.75 %.


En comparación con los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, estos son peores, se tiene un número mayor de aprendizajes no válidos, aprendizajes promedio más bajo y el máximo de respuestas correctas aprendidas también está por debajo.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 30 % son excitatorias y el 70 % restante son inhibitorias, tampoco tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos ya que son solo 5 casos en los que logra aceptar las 4 respuestas correctas.

### PPCR Synaptic 40-60


Individuo = Paro Cardiorrespiratorio  
Neuronas excitatorias = 40 %  
Neuronas inhibitorias = 60 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio con 40 % de las conexiones excitatorias y 60 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 38.55 %, en la figura A.78 se muestra el aprendizaje promedio en cada simulación, que es aún más bajo que en el caso anterior.




**Figura A.78:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_40-60.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar claramente que los resultados no son tan favorables ya que la mayoría son **NA**, sin embargo, el número de simulaciones con comportamientos estables es mayor que en los casos anteriores. En la figura A.79 podemos verificar esta información donde 57 % de las simulaciones tuvieron un comportamiento estable.



**Figura A.79:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Obstacles\_40-60.

Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.80, se observa que en la mayoría de las simulaciones con comportamiento estable se aprendieron 2 respuestas correctas, sólo en una simulación se logró aprender las 4 respuestas correctas.




**Figura A.80:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Obstacles\_40-60.

En la figura A.81, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra por debajo del 68.75% que se consideran aprendizajes bajos y por eso se tiene un aprendizaje


A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorespiratorio.

promedio tan bajo.



**Figura A.81:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_40-60.

En la figura A.82, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Al analizar las gráficas de aprendizaje observamos que se comienzan a tener aprendizajes mayores y comportamientos donde la estabilidad se mantiene durante una mayor parte del tiempo de aprendizaje.



**Figura A.82:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_40-60.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal, donde en uno de los puntos máximos se tiene un 21.4% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas

se obtengan comportamientos estables con un aprendizaje promedio entre 39.81 % y 45.83 %, que son aprendizajes bajos pero mayores a los del caso anterior, lo que explica que el nivel de respuesta en estos casos sea mayor al obtenido con los porcentajes de conexiones sinápticas anteriores.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 40 % de sus conexiones son excitatorias y 60 % inhibitorias, tenemos que con esta relación del 40 %-60 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje tan favorables, ya que en general se obtiene un aprendizaje promedio total bajo, sin embargo, las simulaciones donde no se aprendió nada disminuyó con respecto al caso anterior y en consecuencia se tienen más casos en que el comportamiento se observa gráficamente estable.

Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos que las figuras A.79 y A.80 presentan un comportamiento similar al de las conexiones sinápticas 30 % excitatorias - 70 % inhibitorias, sin embargo, en la figura A.81 se tiene una curva multimodal donde podemos notar que la cantidad de casos con aprendizajes superiores al 43.75 % es mayor con respecto al caso anterior.


Con respecto a los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, nuevamente estos son peores, ya que se tiene un número mayor de aprendizajes no válidos, aprendizajes promedio más bajo y el máximo de respuestas correctas aprendidas también es inferior.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 40 % son excitatorias y el 60 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos, ya que sólo en 1 simulación se logró aprender las 4 respuestas correctas.

### PPCR Synaptic 50-50


Individuo = Paro Cardiorrespiratorio  
Neuronas excitatorias = 50 %  
Neuronas inhibitorias = 50 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio con 50 % de las conexiones excitatorias y 50 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 27.76 %, en la figura A.83 se muestra el aprendizaje promedio en cada simulación, que es muy bajo, aún más que en los tres casos anteriores.




**Figura A.83:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_50-50.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar claramente que los resultados no son tan favorables, ya que la mayoría de las simulaciones tienen comportamiento **NA**, en la figura A.84 podemos verificar esta información donde 56 % de las simulaciones tuvieron un comportamiento donde no se aprendió ninguna respuesta correcta.



**Figura A.84:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.50-50.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.85, se observa que en la mayoría de las simulaciones con comportamiento estable se aprendió solo 1 respuesta correcta, solo en dos se obtuvieron las 4 respuestas correctas.



**Figura A.85:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.50-50.


En la figura A.86, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra por debajo del 50% que se consideran aprendizajes bajos.

A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.



**Figura A.86:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_50-50.

En la figura A.87, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Observamos que la mayoría se concentra en aprendizajes menores al 50%, el comportamiento se mantiene estable la mayor parte del tiempo de aprendizaje pero se obtiene en la mayoría solo 1 o 2 respuestas correctas, por lo que se explican los aprendizajes tan bajos.



**Figura A.87:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_50-50.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal, donde en uno de los puntos máximos se tiene un 22.9% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se

obtengan comportamientos estables con un aprendizaje promedio entre 17% y 23.5%, que son aprendizajes aún más bajos que los casos anteriores, por lo que se explica que el nivel de respuesta haya disminuido con respecto al obtenido en los porcentajes de conexiones sinápticas anteriores.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 50% de sus conexiones son excitatorias y 50% inhibitorias, tenemos que con esta relación del 50%-50% en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje menos favorables, ya que en general se obtiene un aprendizaje promedio total más bajo que en los tres casos anteriores, el total de simulaciones en que no logró aprender es mucho mayor al de los aprendizajes estables.

Si obtenemos la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos que las figuras A.84 y A.85 presentan un comportamiento similar a las de las conexiones sinápticas 10% excitatorias - 90% inhibitorias, ya que se comportan como una función decreciente en las que la probabilidad mayor es para las simulaciones donde no se logra aprender nada. En la figura A.86 se tiene una curva multimodal, donde el punto máximo de probabilidad es para los aprendizajes que se encuentran entre 18.75% y 25%, resultado parecido al de las conexiones 20% excitatorias - 80% inhibitorias y que explica porqué se tienen resultados más bajos que en casos anteriores.


Respecto a los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, estos son peores y además un dato importante a recalcar es que en los dos se tuvieron cambios, respecto a que conforme aumentaban las conexiones sinápticas excitatorias se obtenían mejores resultados, sin embargo, para el caso 50% excitatorias - 50% inhibitorias los resultados empeoraron.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 50% son excitatorias y el 50% restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos ya que se llegan aprender las 4 respuestas correctas solo en 2 casos y en la mayoría solo se aprenden 1 o 2 respuestas correctas, mientras que en el caso anterior ya se tenía un número mayor de simulaciones con 3 respuestas correctas.

### PPCR Synaptic 60-40


Individuo = Paro Cardiorrespiratorio  
Neuronas excitatorias = 60 %  
Neuronas inhibitorias = 40 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio con 60 % de las conexiones excitatorias y 40 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 22.84 %, en la figura A.88 se muestra el aprendizaje promedio en cada simulación, todavía más bajo que el obtenido en el caso anterior.




**Figura A.88:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_60-40.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que la mayoría son **NA**, sin embargo, son más los casos en que se obtuvieron comportamientos estables en comparación a los casos anteriores aunque estos sean bajos, en la figura A.89 podemos observar estos resultados.



**Figura A.89:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.60-40.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.90, se observa que en la mayoría de las simulaciones con comportamiento estable se aprendió solo 1 respuesta correcta, solo en dos simulaciones se logró aprender las 4 respuestas correctas.



**Figura A.90:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.60-40.

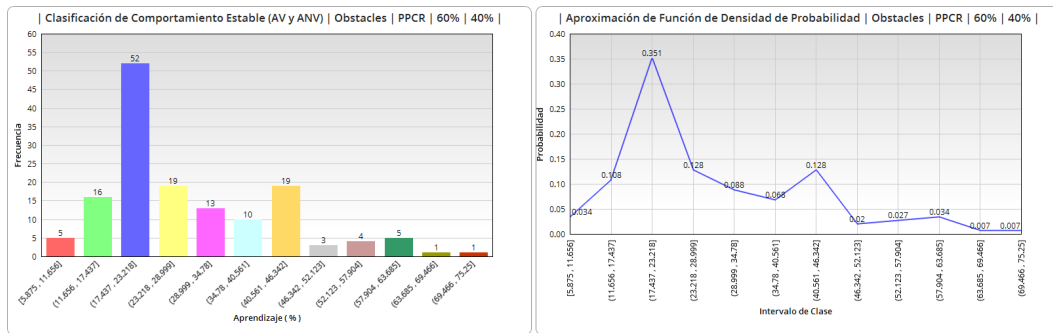
En la figura A.91, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra por debajo del 50% que se consideran aprendizajes bajos.

A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.



**Figura A.91:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_60-40.

En la figura A.92, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Al igual que el caso anterior, la mayoría se concentra en aprendizajes menores al 50 % debido a que aunque se tienen más casos en que el comportamiento se mantiene estable la mayor parte del tiempo de aprendizaje se obtienen a lo mucho 2 respuestas correctas.



**Figura A.92:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_60-40.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal, donde en uno de los puntos máximos se tiene un 35.1% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 17.43 % y 23.21 %, y el otro punto máximo está en el intervalo (40,561, 46,342] con una probabilidad de 0,128.

aprendizajes muy similares a los del caso anterior, sin embargo, el número de simulaciones con comportamientos de aprendizaje estables es superior a los que no lograron aprender nada.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 60 % de sus conexiones son excitatorias y 40 % inhibitorias, tenemos que con esta relación del 60 %-40 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio total bajo, sin embargo, nuevamente tenemos más simulaciones con comportamiento estable en comparación de las que no logran aprender, por lo que podemos decir que son mejores resultados que los anteriores.

Obteniendo la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos que las figuras A.89 y A.90 presentan una curva en forma de J invertida teniendo la mayor probabilidad en los casos en que no logra aprender, sin embargo, en la figura A.91 se tiene una curva multimodal, donde el punto máximo de probabilidad es para los aprendizajes que se encuentran entre 18.75 % y 25 %, resultado parecido al de las conexiones anteriores y que nuevamente se presentan porque se tienen resultados bajos respecto al nivel de respuestas correctas, pero favorables respecto a la clasificación del comportamiento.


En comparación a los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, nuevamente estos son peores, sin embargo, la tendencia que se comenzaba a tener en los primeros 4 casos se retoma, donde la cantidad de aprendizajes no válidos disminuye y en consecuencia aumentan los casos de aprendizajes válidos.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 60 % son excitatorias y el 40 % restante son inhibitorias, en general no tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos, ya que se llegan aprender las 4 respuestas correctas solo en 2 simulaciones y en la mayoría solo se aprenden 1 o 2 respuestas correctas, que es un nivel de respuesta muy bajo.

### PPCR Synaptic 70-30


Individuo = Paro Cardiorrespiratorio  
Neuronas excitatorias = 70 %  
Neuronas inhibitorias = 30 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio con 70 % de las conexiones excitatorias y 30 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 20.47 %, en la figura A.93 se muestra el aprendizaje promedio en cada simulación, nuevamente más bajo que los anteriores.




**Figura A.93:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_70-30.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar que los resultados son favorables ya que la mayoría son **AV**, en la figura A.94 podemos observar que sólo en el 33 % de las simulaciones no se logró aprender nada.



**Figura A.94:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.70-30.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.95, se observa que en la mayoría de las simulaciones con comportamiento estable se aprendió solo 1 respuesta correcta, solo en una simulación se logró aprender las 4 respuestas correctas.



**Figura A.95:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.70-30.

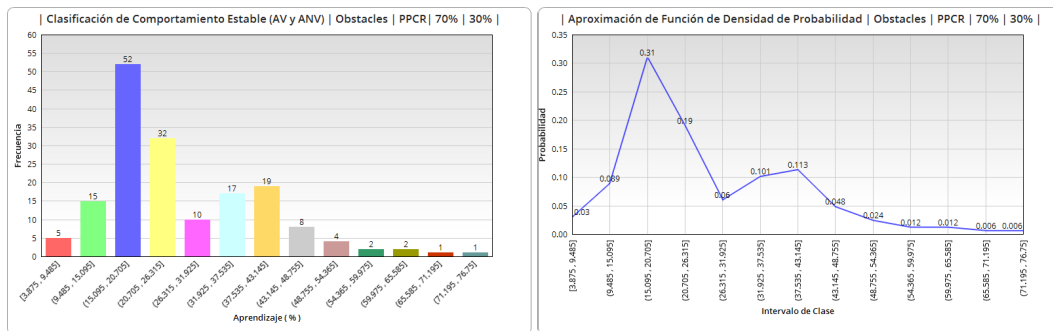
En la figura A.96, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra por debajo del 43.75 % que se consideran aprendizajes muy bajos.

A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.



**Figura A.96:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_70-30.

En la figura A.97, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Se tienen aprendizajes bajos, sin embargo, al analizar las gráficas de aprendizaje la mayoría tienen un comportamiento estable durante un tiempo de aprendizaje mayor que en los otros casos, pero en la mayoría de los casos aprendiendo solo 1 o 2 respuestas correctas.



**Figura A.97:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_70-30.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal muy similar a la del caso anterior donde en uno de los puntos máximos se tiene un 31 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje

promedio entre 15.09 % y 20.70 %, aprendizajes inferiores a los del caso anterior, lo que explica que se tenga un aprendizaje promedio más bajo. Sin embargo, el número de simulaciones con comportamientos de aprendizaje válido es superior a los que no lograron aprender nada.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 70 % de sus conexiones son excitatorias y 30 % inhibitorias, tenemos que con esta relación del 70 %-30 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables en el sentido que se obtuvieron más casos con comportamientos de aprendizaje estables, sin embargo, el aprendizaje en ellos es aún muy bajo, en la mayoría sólo se aprendió una respuesta correcta y sólo en un caso se lograron aprender las 4 respuestas correctas.

Obteniendo la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.94 una curva casi simétrica en la que la probabilidad mayor es para los aprendizajes válidos. En la figura A.95 se presenta una curva suave sesgada a la derecha, teniendo la mayor probabilidad en el caso de obtener solo una respuesta correcta. Por último, en la figura A.96 se tiene una curva multimodal donde los puntos máximos de probabilidad es para los aprendizajes que se encuentran entre 0 % y 6.25 %, donde están incluidos los casos en que lo logra aprender o entre 18.75 % y 25 %, resultado parecido a los dos anteriores porque se tienen resultados bajos respecto al nivel de respuestas correctas, pero favorables respecto a la clasificación del comportamiento.


En comparación a los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, también éstos son peores, sin embargo, para los dos casos se tiene una cantidad mayor de simulaciones con comportamiento válido, sólo que para la persona sana los aprendizajes son mayores al 37.5 % lo que hace que se logre obtener un nivel de respuesta más alto. Otro dato importante es que también en estos resultados se comienza a observar lo que llamamos memoria, ya que los comportamientos se mantienen estables durante un mayor tiempo de aprendizaje y además retienen e incrementan ese conocimiento hasta el final del tiempo de aprendizaje.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 70 % son excitatorias y el 30 % restante son inhibitorias, en general no tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos ya que son muy pocos los casos en que se logran aprender las 4 respuestas correctas.

### PPCR Synaptic 80-20


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 80 %  
Neuronas inhibitorias = 20 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 80 % de las conexiones excitatorias y 20 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 21.27 %, en la figura A.98 se muestra el aprendizaje promedio en cada simulación, sigue siendo bajo pero un poco mayor al del caso anterior.




**Figura A.98:** Gráfica del aprendizaje promedio para cada simulación de PPCR.Obstacles\_80-20.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar que los resultados son favorables ya que la mayoría se encuentra en **AV**, en la figura A.99 podemos observar que sólo en el 27 % de las simulaciones no se logra aprender nada, porcentaje menor que en el caso anterior.



**Figura A.99:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.80-20.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.100, se observa que en la mayoría de las simulaciones con comportamiento estable se aprendió solo 1 respuesta correcta, en ninguna simulación se logró aprender las 4 respuestas correctas.



**Figura A.100:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.80-20.


En la figura A.101, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra por debajo del 25 %, lo que se considera aprendizajes demasiado bajos.

A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.



**Figura A.101:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_80-20.

En la figura A.102, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Analizando las gráficas observamos que se tienen aprendizajes bajos debido a que se aprenden muy pocas respuestas correctas, sin embargo, el comportamiento estable se mantiene durante la mayor parte del tiempo del aprendizaje.



**Figura A.102:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_80-20.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal con dos puntos máximos, donde se tiene un 23% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 13.07% y 22.39%.

aprendizajes similares a los del caso anterior.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 80 % de sus conexiones son excitatorias y 20 % inhibitorias, tenemos que con esta relación del 80 %-20 % en conexiones excitatorias - inhibitorias, al igual que el caso anterior obtenemos resultados de aprendizaje favorables en el sentido que se obtuvieron más casos en que se obtienen comportamientos de aprendizaje estables, sin embargo, el aprendizaje en ellos es muy bajo, en la mayoría sólo se aprendió una respuesta correcta y en este caso en ninguna simulación se aprendieron las 4 respuestas correctas.

Obteniendo la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.99 una curva casi simétrica en la que la probabilidad mayor es para los aprendizajes válidos al igual que en el caso anterior pero en la que la probabilidad de que se obtengan simulaciones en las que no se aprende nada es menor. En la figura A.100 se presenta una curva suave sesgada a la derecha, teniendo la mayor probabilidad en el caso de obtener solo una respuesta correcta. Por último en la figura A.101 se tiene una curva multimodal también similar a la del caso anterior pero donde los puntos máximos de probabilidad es para los aprendizajes que se encuentran entre 12.5 % y 18.75 % o entre 18.75 % y 25 %, resultado mejor a los 3 anteriores pero parecido porque se tienen resultados bajos respecto al nivel de respuestas correctas y favorables respecto a la clasificación del comportamiento.


En comparación a los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, estos son peores, sin embargo, para los dos casos se tiene una cantidad mayor de simulaciones con comportamiento válido, pero para la persona sana los aprendizajes son mayores al 37.5 % lo que hace que se logre obtener un nivel de respuesta más alto y además la característica de tener memoria también se conserva al tener comportamientos en los que no se tienen fluctuaciones sino que el aprendizaje aumenta sin olvidar lo ya aprendido.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 80 % son excitatorias y el 20 % restante son inhibitorias, en general no tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos ya que en ninguna simulación logró aprender las 4 respuestas correctas.

### PPCR Synaptic 90-10


Individuo = Paro Cardiorrespiratorio  
Neuronas excitatorias = 90 %  
Neuronas inhibitorias = 10 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio con 90 % de las conexiones excitatorias y 10 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 19.58 %, en la figura A.103 se muestra el aprendizaje promedio en cada simulación, que es más bajo que en los siete casos anteriores.




**Figura A.103:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_90-10.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar que los resultados son favorables, ya que la mayoría se encuentra en la clase **AV**, en la figura A.104 podemos observar que solo en el 25 % de las simulaciones no se logra aprender nada.



**Figura A.104:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.90-10.


Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.105, se observa que en la mayoría de las simulaciones con comportamiento estable se aprendió sólo 1 respuesta correcta y en ninguna simulación se logró aprender las 4 respuestas correctas.



**Figura A.105:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.90-10.


En la figura A.106, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra por debajo del 25 %, lo que se considera aprendizajes demasiado bajos.

A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.



**Figura A.106:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_90-10.

En la figura A.107, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Se tienen muy pocos casos en que los aprendizajes son altos, sin embargo, el aprendizaje ocurre mucho antes del 50% del tiempo total del aprendizaje y se mantiene estable hasta el final, al igual que en los dos casos anteriores.



**Figura A.107:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_90-10.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal muy similar a la del caso anterior donde en uno de los puntos máximos se tiene un 20.4% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje

promedio entre 14.46 % y 18.51 %, aprendizajes un poco inferiores a los del caso anterior.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 90 % de sus conexiones son excitatorias y 10 % inhibitorias, tenemos que con esta relación del 90 %-10 % en conexiones excitatorias - inhibitorias, al igual que el caso anterior obtenemos resultados de aprendizaje favorables en el sentido que se obtuvieron más casos con comportamientos de aprendizaje válido, sin embargo, el aprendizaje en ellos es muy bajo, en la mayoría sólo se aprendió una respuesta correcta y al igual que en el caso anterior en ninguna simulación se aprendieron las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.104 una curva casi simétrica en la que la probabilidad mayor es para los aprendizajes válidos al igual que en los dos casos anteriores. En la figura A.105 se presenta una curva suave sesgada a la derecha, teniendo la mayor probabilidad en el caso de obtener solo una respuesta correcta al igual que el caso anterior. Por último en la figura A.106 se tiene una curva multimodal también muy similar a la de los dos casos anteriores, pero donde los puntos máximos de probabilidad es para los aprendizajes que se encuentran entre 0 % y 6.25 % o entre 18.75 % y 25 %, resultado muy parecido al anterior.


En comparación a los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, estos son peores, sin embargo, para los dos casos se tiene una cantidad mayor de simulaciones con comportamiento válido solo que para la persona sana los aprendizajes son mayores al 25 % lo que hace que se logre obtener un nivel de respuesta más alto, logrando en unas cuantas simulaciones que se obtengan 3 o 4 respuestas correctas pero además la característica de tener memoria también se conserva al tener comportamientos en los que no se tienen fluctuaciones.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 90 % son excitatorias y el 10 % restante son inhibitorias, tampoco tendrá un desempeño favorable al realizar la actividad de caminar sufriendo mioclonías al presentarle varios obstáculos por los mismos motivos que en el caso anterior.

### PPCR Synaptic 100-0


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 100 %  
Neuronas inhibitorias = 0 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 90 % de las conexiones excitatorias y 10 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 47.92 %, en la figura A.108 se muestra el aprendizaje promedio en cada simulación, que es bajo pero el más alto con respecto a los casos anteriores.




**Figura A.108:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Obstacles\_100-0.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar que los resultados son favorables ya que la mayoría se encuentra en **AV** y **ANV**. En la figura A.109 podemos observar que solo en el 8 % de las simulaciones no se logra aprender nada.



**Figura A.109:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR.Obstacles.100-0.

Al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.110, se observa que en la mayoría de las simulaciones con comportamiento estable se aprendieron 3 respuestas correctas y en solo 13 simulaciones se logró aprender las 4 respuestas correctas.




**Figura A.110:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR.Obstacles.100-0.

En la figura A.111, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra entre 37.5% y 68.75% considerados como aprendizajes bajos, pero mejores que en los casos


A.10 Resultados de RMCS para dificultad al caminar de individuo que sufrió paro cardiorrespiratorio.

anteriores.



**Figura A.111:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Obstacles\_100-0.

En la figura A.112, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. La mayoría están por encima del 40 % ya que los comportamiento mantienen su estabilidad por más de la mitad del tiempo total del aprendizaje y se alcanza a obtener un mayor número de respuestas correctas que en los casos anteriores.



**Figura A.112:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Obstacles\_100-0.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal donde en uno de los puntos máximos se tiene un 20.9% de probabilidad de que al

realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 42.97 % y 47.57 % y un 18.3 % de probabilidad de que el aprendizaje esté entre 61.37 % y 65.97 % , aprendizajes superiores a cualquiera de los casos anteriores.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorrespiratorio que realiza una actividad cotidiana como es caminar y poder evitar cualquier obstáculo que se le presente durante su camino y donde el 100 % de sus conexiones son excitatorias y 0 % inhibitorias, tenemos que con la relación del 100 %-0 % en conexiones excitatorias - inhibitorias se obtienen resultados satisfactorios de acuerdo a que el aprendizaje promedio total es más alto que en los casos anteriores, pero en general sigue siendo bajo, sin embargo, el total de simulaciones que se consideran como aprendizajes válidos es cada vez mayor conforme aumentan las conexiones excitatorias, es decir los comportamientos son mejores pero el nivel de respuesta es aún muy bajo.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.109 una curva creciente en la que la probabilidad mayor es para los aprendizajes válidos. En la figura A.110 se presenta una curva suave sesgada a la izquierda donde la mayor probabilidad es para el caso de obtener 3 respuestas correctas, el mejor caso obtenido respecto a todos los anteriores y por último en la figura A.111 se tiene una curva multimodal, donde los puntos máximos de probabilidad es para los aprendizajes que se encuentran entre 43.75 % y 50 % o entre 56.25 % y 62.5 %, resultado mayor a todos los anteriores.

En comparación a los resultados de una persona sana con los mismos porcentajes en sus conexiones sinápticas, a pesar de ser los mejores para una persona que sufrió un paro cardiorrespiratorio también estos son peores respecto a los del individuo sano, sin embargo, para los dos casos se tiene una cantidad mayor de simulaciones con comportamiento válido y la característica de tener memoria se sigue conservando ya que no se tienen comportamientos con fluctuaciones.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal no tendrá un desempeño favorable en el total de los casos al realizar la actividad de caminar de manera normal al presentarle varios obstáculos, ya que en la mayoría logra aprender sólo 3 respuestas correctas y en muy pocos casos se alcanzan a obtener las 4 respuestas correctas, además de manera biológica es poco probable que se pueda realizar este tipo de conexión por los motivos que ya se explicaron anteriormente y mucho menos en una persona que sufrió un paro cardiorrespiratorio ya que con una lesión cerebral se pierden o debilitan conexiones sinápticas.

## A.11. Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.


### PNormal Synaptic 10-90

Individuo = Normal

Neuronas excitatorias = 10 %


Neuronas inhibitorias = 90 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 10 % de las conexiones excitatorias y 90 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 0 %, en la figura A.113 se muestra el aprendizaje promedio en cada simulación, notamos que en ninguna simulación logró aprender.




**Figura A.113:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_10-90.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables, ya que todos se encuentran en **NA**. En la figura A.114 podemos verificar esta información donde el 100 % de las simulaciones tuvieron un comportamiento donde no se aprendió nada.



**Figura A.114:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Objects\_10-90.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.115, se observa que todas se sitúan en 0 respuestas correctas.



**Figura A.115:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_10-90.

En la figura A.116, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como todos se encuentran en el intervalo  $[0, 6.25]$ .

A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.



**Figura A.116:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_10-90.

Para este caso no se realizó la clasificación del comportamiento de aprendizaje estable ya que en ninguna de las 251 simulaciones obtuvimos un aprendizaje mayor a 0.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 10 % de sus conexiones son excitatorias y 90 % inhibitorias, tenemos que con esta relación del 10 %-90 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio nulo, es decir, nunca aprendió nada.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos que para todas únicamente se tiene un punto máximo donde se indica que se tiene el 100 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan siempre comportamientos en los que no aprende absolutamente nada y en consecuencia se tengan 0 respuestas correctas.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 10 % son excitatorias y el 90 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media - pequeña que le sea presentado.


**PNormal Synaptic 20-80**

Individuo = Normal

Neuronas excitatorias = 20 %

Neuronas inhibitorias = 80 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 20 % de las conexiones excitatorias y 80 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 37.1 %, en la figura A.117 se muestra el aprendizaje promedio en cada simulación, con esto fue que se calculó el aprendizaje promedio total, que se considera muy bajo ya que en todas las simulaciones tenemos aprendizajes por debajo del 50 %.




**Figura A.117:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_20-80.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que la mayoría se encuentra en **NA**. En la figura A.118 podemos verificar esta información donde el 68 % de las simulaciones fueron en las que no se logra aprender nada.


A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.

---




**Figura A.118:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Obstacles\_20-80.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.119, se observa que de las 80 simulaciones que tuvieron un comportamiento estable, en 62 de ellas se logró aprender 2 respuestas correctas y en el resto solo 1.



**Figura A.119:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_20-80.


En la figura A.120, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como todos están por debajo del 50%.



**Figura A.120:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_20-80.

Después de realizar la clasificación del comportamiento de aprendizaje, se realizó un histograma de frecuencias del aprendizaje obtenido en las simulaciones que fueron clasificadas como AV y ANV, es decir, únicamente de los comportamientos estables y con éste se obtuvo la aproximación de la función de densidad de probabilidad, los resultados obtenidos se muestran en la figura A.121.

Se tienen valores de aprendizaje bajos ya que todos están por debajo del 50%, esto se debe a que el número de respuestas correctas es muy bajo, ya que a lo más se logran aprender solo 2, además se tienen simulaciones que inician con fluctuaciones, se mantiene por un momento así y después logran estabilizarse.



**Figura A.121:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_20-80.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva bimodal,

donde en uno de los puntos máximos se tiene un 35 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 41.07 % y 44.59 % y un 18.8 % de probabilidad de que el aprendizaje esté entre 19.90 % y 23.43 %. Se considera que en el primer intervalo se encuentran las simulaciones en las que se lograron aprender 2 respuestas, mientras que en el segundo algunas en las que sólo se obtuvo 1 respuesta correcta.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 20 % de sus conexiones son excitatorias y 80 % inhibitorias, tenemos que con esta relación del 20 %-80 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio bajo y sólo se lograron aprender como máximo 2 respuestas correctas en los comportamientos válidos.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.118 una curva en forma de J invertida, es decir, una función decreciente en la que la probabilidad mayor es para los aprendizajes no válidos, o sea en los que no logra aprender nada. En la figura A.119 se presenta una curva bimodal, donde los puntos máximos de probabilidad son para obtener 0 o 2 respuestas correctas. Por último en la figura A.120 se tiene una curva multimodal, donde uno de los puntos máximos de probabilidad es para los aprendizajes que se encuentran entre 37.5 % y 43.75 % que son los aprendizajes, aprendizajes principalmente obtenidos en las simulaciones donde se obtuvieron las 2 respuestas correctas.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 20 % son excitatorias y el 80 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media-pequeña que le sea presentado ya que en ningún caso se pudieron aprender las 4 respuestas correctas.


**PNormal Synaptic 30-70**

Individuo = Normal

Neuronas excitatorias = 30 %

Neuronas inhibitorias = 70 %


Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 30 % de las conexiones excitatorias y 70 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 68.59 %, en la figura A.122 se muestra el aprendizaje promedio en cada simulación, que a pesar de ser mayor al 50 % y mayor a los casos anteriores se sigue considerando bajo.



**Figura A.122:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_30-70.


Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables, ya que la mayoría se encuentra en **NA**. En la figura A.123 podemos verificar esta información donde el 68 % de las simulaciones fueron en las que no se logra aprender nada.

A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.




**Figura A.123:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Obstacles\_30-70.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.124, se observa que de las 80 simulaciones que tuvieron un comportamiento estable, en 49 de ellas se logró aprender 4 respuestas correctas.




**Figura A.124:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_30-70.

En la figura A.125, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 56.25 % al 87.5 %.



**Figura A.125:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_30-70.

En la figura A.126, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Se tienen valores de aprendizaje altos ya que al analizar las gráficas de aprendizaje observamos que la mayoría está por encima del 60%. Al igual que en el caso anterior la mayoría de las simulaciones comienzan con fluctuaciones pero para éste caso esas fluctuaciones se presentan por menos tiempo y haciendo que la estabilidad se mantenga por un tiempo mayor y además se tienen casos en que aprende las 4 respuestas correctas.



**Figura A.126:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_30-70.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva bimodal, donde en uno de los puntos máximos se tiene un 30% de probabilidad de que al reali-

zar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 80.37 % y 86.62 %, que esta vez se consideran muy buenos ya que son mucho más altos que en el caso anterior y además son los aprendizajes obtenidos en las simulaciones que si lograron aprender las 4 respuestas correctas que es uno de los principales objetivos.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 30 % de sus conexiones son excitatorias y 70 % inhibitorias, tenemos que con esta relación del 30 %-70 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje no tan favorables ya que en general se obtiene un aprendizaje promedio no tan bajo pero se obtuvieron solo en un 32 % de las simulaciones aprendizajes válidos y en la mitad de ellos se lograron aprender las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, en la figura A.123 se sigue presentando una curva en forma de J invertida, es decir, una función decreciente en la que la probabilidad mayor es para los aprendizajes no válidos al igual que en el caso anterior. En la figura A.124 se presenta una curva bimodal, donde los puntos máximos de probabilidad son para obtener 0 o 4 respuestas correctas, que ya son mejores condiciones en comparación al caso anterior en que a lo mucho logro solo 2 respuestas correctas. Por último en la figura A.125 se tiene una curva suave sesgada a la izquierda, es decir, está más cargada hacia los aprendizajes mayores al 50 %, esto se debe a que los aprendizajes válidos lograron aprender las 4 respuestas correctas pero también se están presentando simulaciones con comportamientos de aprendizaje no válidos que al tener tantas fluctuaciones logran tener un aprendizaje promedio alto.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 30 % son excitatorias y el 70 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media- pequeña que le sea presentado ya que aún se consideran muy pocos los casos en los que se aprenden las 4 respuestas correctas, la mayoría siguen siendo comportamientos no válidos.


**PNormal Synaptic 40-60**

Individuo = Normal

Neuronas excitatorias = 40 %

Neuronas inhibitorias = 60 %


Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 40 % de las conexiones excitatorias y 60 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 82.8 %, en la figura A.127 se muestra el aprendizaje promedio en cada simulación, que en este caso se considera bueno ya que es mucho mejor que los anteriores.



**Figura A.127:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_40-60.


Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**, en la figura A.128 podemos verificar esta información donde sólo el 21 % de las simulaciones fueron en las que no se logró aprender nada.

A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.




**Figura A.128:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Objects\_40-60.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.129, se observa que de las 198 simulaciones que tuvieron un comportamiento estable, en 179 de ellas se logró aprender 4 respuestas correctas, el resto sólo aprendió 3.



**Figura A.129:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_40-60.


En la figura A.130, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 81.25 % al 93.75 % lo que es muy bueno.



**Figura A.130:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_40-60.

En la figura A.131 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad para éste histograma.

Observamos que se tienen aprendizajes mayores al 80 %, al igual que en el caso anterior el aprendizaje comienza con fluctuaciones pero logra estabilizarse y esto se mantiene la mayor parte del tiempo de aprendizaje, además que son más casos en los que logran aprender las 4 respuestas correctas.



**Figura A.131:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_40-60.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva no tan suave pero sesgada a la izquierda, donde en el punto máximo se tiene un 23.7 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones

sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 88.93 % y 91.81 % que son mejores que en el caso anterior, ya que son los aprendizajes obtenidos en las simulaciones que si lograron aprender las 4 respuestas que en éste caso es mayor a las que no lograron aprender nada.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 40 % de sus conexiones son excitatorias y 60 % inhibitorias, tenemos que con esta relación del 40 %-60 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio bueno y se obtuvo casi un 80 % del total de las simulaciones con aprendizajes válidos donde un 90 % de ellas obtuvieron las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, en la figura A.128 se presenta una curva casi simétrica en la que la probabilidad mayor es para los aprendizajes válidos. En la figura A.129 se presenta una curva en forma de U pero no simétrica donde el punto máximo de probabilidad es para obtener las 4 respuestas correctas, resultado mucho mejor que el del caso anterior. Por último en la figura A.130 se tiene una curva suave sesgada a la izquierda, es decir, está más cargada hacia los aprendizajes mayores pero en este caso son superiores al 60 %, esto se debe a que la mayoría de las simulaciones fueron aprendizajes válidos y lograron aprender las 4 respuestas correctas.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 40 % son excitatorias y el 60 % restante son inhibitorias, tendrá un desempeño favorable en la mayoría de los casos al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media-pequeña que le sea presentado en comparación con cualquiera de los casos anteriores.


**PNormal Synaptic 50-50**

Individuo = Normal

Neuronas excitatorias = 50 %

Neuronas inhibitorias = 50 %


Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 50 % de las conexiones excitatorias y 50 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 86.94 %, en la figura A.132 se muestra el aprendizaje promedio en cada simulación, que también en éste caso se considera bueno ya que es mayor que los anteriores.



**Figura A.132:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_50-50.


Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**. En la figura A.133 podemos verificar esta información donde sólo en 6 de las simulaciones fue en las que no se logró aprender nada.

A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.




**Figura A.133:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Obstacles\_50-50.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.134, se observa que de las 245 simulaciones que tuvieron un comportamiento estable, en 243 de ellas se logró aprender 4 respuestas correctas, el resto sólo aprendió 3.



**Figura A.134:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_50-50.


En la figura A.135, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 81.25 % al 93.75 % lo que es muy bueno.



**Figura A.135:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_50-50.

En la figura A.136 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma.

En este caso tenemos aprendizajes mayores al 86 %, mejores resultados aunque en el caso anterior, al analizar las gráficas de aprendizaje observamos que para este caso ya no se tienen las fluctuaciones con las que se iniciaba el aprendizaje en los casos anteriores, aquí el comportamiento se mantiene estable desde que inicia hasta el final del tiempo de aprendizaje y además la cantidad de simulaciones en las que se logra aprender las 4 respuestas correctas es mucho mayor.



**Figura A.136:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_50-50.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva sesgada

a la izquierda, donde en el punto máximo se tiene un 27.3 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 88 % y 90 % que son muy parecidos a los del caso anterior, ya que son los aprendizajes obtenidos en las simulaciones que si lograron aprender las 4 respuestas que en este caso también es mayor a las que no lograron aprender nada.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 50 % de sus conexiones son excitatorias y 50 % inhibitorias, tenemos que con esta relación del 50 %-50 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje más favorables que en el caso anterior, ya que en general se obtiene un aprendizaje promedio bueno, y en este caso casi todas aprendieron a responder las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, en la figura A.133 se presenta una curva sesgada a la izquierda en la que la probabilidad mayor es para los aprendizajes válidos. En la figura A.134 se presenta una curva en forma de J, es decir, una función creciente donde el punto máximo de probabilidad es para obtener las 4 respuestas correctas, en comparación con los resultados del caso anterior, éstos son mejores ya que la probabilidad de obtener 0 respuestas correctas es casi nula. Por último en la figura A.135 se tiene una curva sesgada a la izquierda, es decir, está más cargada hacia los aprendizajes mayores que en este caso son superiores al 81.25 %, resultados más satisfactorios en comparación que con los casos anteriores, en especial el de las conexiones 40 % excitatorias - 60 % inhibitorias que fue donde se comenzó a dar este cambio.

Como en el problema de la dificultad al caminar se mencionó tener la característica de la memoria a largo plazo, aquí también se presentó pero comenzó presentándose con un número menor de conexiones excitatorias, ya que en el problema anterior se dio a partir de las conexiones 70 % excitatorias - 30 % inhibitorias.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 50 % son excitatorias y el 50 % restante son inhibitorias, en general tendrá un desempeño favorable en la gran mayoría de los casos al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media- pequeña que le sea presentado, ya que se tuvieron comportamientos de aprendizaje muy buenos incluyendo que poseen la característica de tener memoria a largo plazo.


**PNormal Synaptic 60-40**

Individuo = Normal

Neuronas excitatorias = 60 %

Neuronas inhibitorias = 40 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 60 % de las conexiones excitatorias y 40 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 86.24 %, en la figura A.137 se muestra el aprendizaje promedio en cada simulación, que en este caso también se considera bueno ya que es un poco menor al del caso anterior pero mejor que los 4 anteriores.




**Figura A.137:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_60-40.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**. En la figura A.138 podemos verificar esta información donde solo en 10 de las simulaciones fue en las que no se logró aprender nada.


A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.

---




**Figura A.138:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Obstacles\_60-40.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.139, se observa que de las 241 simulaciones que tuvieron un comportamiento estable, en 238 de ellas se logró aprender 4 respuestas correctas, el resto solo aprendió 3.




**Figura A.139:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_60-40.

En la figura A.140, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 81.25 % al 93.75 % al igual que en el caso anterior.



**Figura A.140:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_60-40.

En la figura A.141 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Se tienen aprendizajes mayores al 85 % ya que al igual que en los casos anteriores el comportamiento estable se mantiene la mayor parte del tiempo aprendizaje y también se logran aprender las 4 respuestas correctas.



**Figura A.141:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_60-40.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva sesgada a la izquierda donde en el punto máximo se tiene un 27.4 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 88.02 % y 90.17 %,.

resultados similares a los de los casos anteriores ya que son los aprendizajes obtenidos en las simulaciones que si lograron aprender las 4 respuestas, donde nuevamente se tienen más simulaciones con comportamientos válidos.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 60 % de sus conexiones son excitatorias y 40 % inhibitorias, tenemos que con esta relación del 60 %-40 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio bueno, se obtuvieron aprendizajes válidos en un 96 % de las simulaciones y en la mayoría de estas se aprendieron a responder las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, en la figura A.138 se presenta una curva sesgada a la izquierda en la que la probabilidad mayor es para los aprendizajes válidos al igual que en los dos casos anteriores. En la figura A.139 se presenta una curva en forma de J, es decir, una función creciente donde también el punto máximo de probabilidad es para obtener las 4 respuestas correctas. Por último en la figura A.140 también se tiene una curva sesgada a la izquierda, es decir, está más cargada hacia los aprendizajes mayores que en éste caso son superiores al 81.25 %, resultados similares a los del caso anterior.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 60 % son excitatorias y el 40 % restante son inhibitorias, también tendrá un desempeño favorable en la gran mayoría de los casos al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media- pequeña que le sea presentado, ya que el número de simulaciones con aprendizajes válidos es bueno y muy importante que se sigue teniendo presente la característica de la memoria a largo plazo, ya que además de aprender rápido, lo que aprende no lo olvida conforme pasa el tiempo.


**PNormal Synaptic 70-30**

Individuo = Normal

Neuronas excitatorias = 70 %

Neuronas inhibitorias = 30 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 70 % de las conexiones excitatorias y 30 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 83.47 %, en la figura A.142 se muestra el aprendizaje promedio en cada simulación, que en este caso es un poco más bajo que los dos anteriores, pero se sigue considerando bueno.




**Figura A.142:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_70-30.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**, en la figura A.143 podemos verificar esta información donde solo en 10 de las simulaciones fue en las que no se logró aprender nada.


A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.

---




**Figura A.143:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Obstacles\_70-30.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.144, se observa que de las 241 simulaciones que tuvieron un comportamiento estable, en 219 de ellas se logró aprender 4 respuestas correctas, el resto sólo aprendió 3.




**Figura A.144:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_70-30.

En la figura A.145, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 81.25 % al 93.75 % al igual que en el caso anterior.



**Figura A.145:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_70-30.

En la figura A.146 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Al igual que en los casos anteriores los aprendizajes son mayores al 80 %, ya que como se ha venido mencionando el comportamiento estable se mantiene la mayor parte del tiempo total de aprendizaje y aquí también la mayoría de los caso logran aprender las 4 respuestas correctas.



**Figura A.146:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_70-30.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva sesgada a la izquierda donde en el punto máximo se tiene un 24.5 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se ob-

tengan comportamientos estables con un aprendizaje promedio entre 85.47 % y 90.41 % resultados similares a los que ya se han venido presentando en los casos anteriores.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 70 % de sus conexiones son excitatorias y 30 % inhibitorias, tenemos que con esta relación del 70 %-30 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio bueno, se obtuvieron aprendizajes válidos en un 96 % de las simulaciones y en la mayoría de estas se aprendieron a responder las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, podemos notar como los resultados son muy similares que los del caso anterior. En la figura A.143 se presenta una curva sesgada a la izquierda en la que la probabilidad mayor es para los aprendizajes válidos. En la figura A.144 nuevamente se presenta una curva en forma de J, es decir, una función creciente donde también el punto máximo de probabilidad es para obtener las 4 respuestas correctas. Por último en la figura A.145 también se tiene una curva sesgada a la izquierda, cargada hacia los aprendizajes mayores que en este caso también son superiores al 81.25 %.

Es importante mencionar que también se tiene presente la característica que define la memoria a largo plazo.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 70 % son excitatorias y el 30 % restante son inhibitorias, tendrá un desempeño favorable en la gran mayoría de los casos al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media- pequeña que le sea presentado ya que los resultados son similares a los casos anteriores.


**PNormal Synaptic 80-20**

Individuo = Normal

Neuronas excitatorias = 80 %

Neuronas inhibitorias = 20 %


Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 80 % de las conexiones excitatorias y 20 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 83.34 %, en la figura A.147 se muestra el aprendizaje promedio en cada simulación, que en éste caso es un poco más bajo que los anteriores pero de igual manera considerado como bueno por ser mayor al 80 %.



**Figura A.147:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects.80-20.


Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**, en la figura A.148 podemos verificar esta información donde sólo en 2 de las simulaciones fue en las que no se logró aprender nada.

A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.




**Figura A.148:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Obstacles\_80-20.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.149, se observa que de las 249 simulaciones que tuvieron un comportamiento estable, en 237 de ellas se logró aprender 4 respuestas correctas, el resto sólo aprendió 3.




**Figura A.149:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_80-20.

En la figura A.150, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 81.25 % al 87.5 % al igual que en el caso anterior.



**Figura A.150:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_80-20.

En la figura A.151, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Aquí también tenemos aprendizajes mayores al 81 % tendencia que se ha venido conservando desde ya hace varias simulaciones.



**Figura A.151:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_80-20.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que en este caso también se tiene una curva sesgada a la izquierda, donde en el punto máximo se tiene un 16.5 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 83.52 % y 89.35 % que son aprendizajes un poco menores a los casos anteriores,

sin embargo, siguen siendo muy buenos.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 80 % de sus conexiones son excitatorias y 20 % inhibitorias, tenemos que con esta relación del 80 %-20 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio bueno, se obtuvieron en un 99 % de las simulaciones aprendizajes válidos y en la mayoría de estas se aprendieron a responder las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, podemos notar como los resultados son muy similares que los de los casos anteriores ya que las curvas de las figuras A.148 y A.149 se presentan las mismas características que en el caso anterior y en la figura A.150 también se tiene una curva sesgada a la izquierda, cargada hacia los aprendizajes mayores, en este caso el intervalo donde se tiene la mayor acumulación es entre 81.25 % y 87.5 %.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 80 % son excitatorias y el 20 % restante son inhibitorias, tendrá un desempeño favorable en la gran mayoría de los casos al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media- pequeña que le sea presentado ya que se tuvieron más casos en los que logró aprender las 4 respuestas correctas y menos en las que no logro aprender nada, por lo menos en comparación con los dos casos anteriores, además al analizar las gráficas de aprendizaje observamos que la característica de la memoria a largo plazo aún se tiene presente con este porcentaje en las conexiones sinápticas.


**PNormal Synaptic 90-10**

Individuo = Normal

Neuronas excitatorias = 90 %

Neuronas inhibitorias = 10 %


Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 90 % de las conexiones excitatorias y 10 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 82.66 %, en la figura A.152 se muestra el aprendizaje promedio en cada simulación, que en éste caso también se considera bueno por ser mayor al 80 %.



**Figura A.152:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_90-10.


Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**. En la figura A.153 podemos verificar esta información donde en este caso no se tuvo ninguna simulación en las que no se logró aprender nada, para todas tuvimos aprendizajes estables.

A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.




**Figura A.153:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal\_Obstacles\_90-10.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.154, se observa que en la mayoría se lograron aprender las 4 respuestas correctas y lo sólo en una simulación logró aprender solo 1 respuesta correcta.




**Figura A.154:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal\_Objects\_90-10.

En la figura A.155 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 81.25 % al 93.75 % al igual que en el caso anterior.



**Figura A.155:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_90-10.

En la figura A.156 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Se tienen aprendizajes mayores al 81 % ya que aquí también el comportamiento estable se mantiene la mayor parte del tiempo total de aprendizaje y se logran aprender las 4 respuestas correctas, además en todas las simulaciones se obtuvieron aprendizajes con comportamientos estables.



**Figura A.156:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_90-10.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva bimodal sesgada a la izquierda, donde los puntos máximos se dan con un 22.3 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápti-

cas se obtengan comportamientos estables con un aprendizaje promedio entre 81.46 % y 84.29 % y un 25.1 % de probabilidad de que se obtengan aprendizajes promedio entre 87.12 % y 89.95 % que son aprendizajes muy parecidos a los obtenidos en los casos anteriores y que son considerados como muy buenos, ya que pertenecen a las simulaciones en las que logra aprender las 4 respuestas correctas.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 90 % de sus conexiones son excitatorias y 10 % inhibitorias, tenemos que con esta relación del 90 %-10 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio bueno, y se obtuvieron en un 100 % de las simulaciones aprendizajes estables donde en un 88 % de estas se obtuvieron las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, en la figura A.153 observamos una curva donde la probabilidad para los casos en que se obtienen comportamientos no válidos y la máxima probabilidad es para los aprendizajes con comportamientos estables y mayores a la media. En la figura A.154 se presenta nuevamente una curva con forma de J donde la probabilidad mayor es para obtener las 4 respuestas correctas, mismas características que se han presentado ya en casos anteriores. Por último en la figura A.155 también se tiene una curva sesgada a la izquierda, cargada hacia los aprendizajes mayores, en este caso el intervalo donde se tiene la mayor acumulación es entre 81.25 % y 87.5 %.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 90 % son excitatorias y el 10 % restante son inhibitorias, tendrá un desempeño favorable al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media-pequeña que le sea presentado al tener resultados muy parecidos a los anteriores y la memoria a largo plazo se sigue presentando.


**PNormal Synaptic 100-0**

Individuo = Normal

Neuronas excitatorias = 100 %

Neuronas inhibitorias = 0 %

Para la simulación de las conexiones sinápticas de un individuo normal (sano) con 90 % de las conexiones excitatorias y 10 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 87.57 %, en la figura A.157 se muestra el aprendizaje promedio en cada simulación, que en este caso es el mejor obtenido respecto a los casos anteriores.




**Figura A.157:** Gráfica del aprendizaje promedio para cada simulación de PNormal\_Objects\_100-0.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**. En la figura A.158 podemos verificar esta información donde la cantidad de simulaciones en **AV** y **ANV** son casi iguales.


A.11 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo sano.

---




**Figura A.158:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PNormal.Obstacles.100-0.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.159, se observa que en todas las simulaciones se lograron aprender las 4 respuestas correctas.



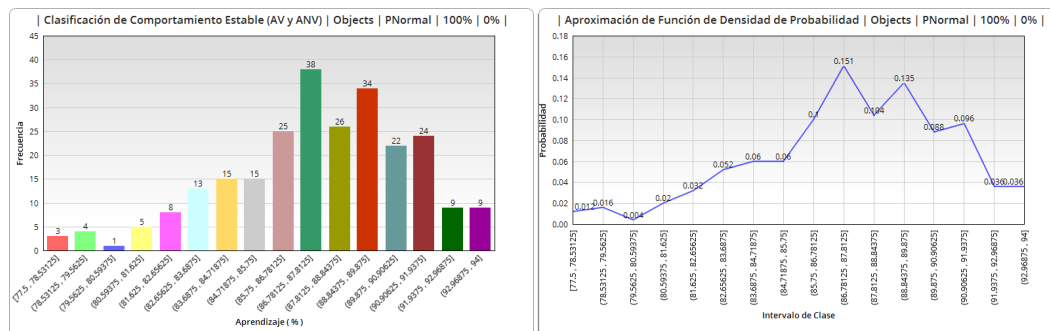
**Figura A.159:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PNormal.Objects.100-0.

En la figura A.160, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayor concentración se encuentra entre el 81.25 % al 93.75 % al igual que en casos anteriores.



**Figura A.160:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PNormal\_Objects\_100-0.

En la figura A.161, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Todos los aprendizajes son mayores a 75 %, se obtuvieron únicamente comportamientos de aprendizaje valido y todos con las 4 respuestas correctas.



**Figura A.161:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PNormal\_Objects\_100-0.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva no tan suave sesgada a la izquierda donde el punto mayor se da con un 15.1 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 86.78 % y 87.81 % que son aprendizajes muy parecidos a los obtenidos en los casos anteriores

ya que en todas las simulaciones se obtienen las 4 respuestas correctas.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo sano que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar de manera normal cualquiera de estos objetos y donde el 100 % de sus conexiones son excitatorias y 0 % inhibitorias, tenemos que con esta relación del 100 %-0 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio bastante alto, y se obtuvieron en un 100 % de las simulaciones aprendizajes estables y en todas se obtuvieron las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos que para las figuras A.158, A.159 y A.160 se tienen las mismas características ya que los resultados fueron muy similares, con la diferencia de que todas las simulaciones aprendieron las 4 respuestas correctas y que en la figura A.160 la probabilidad mayor se da para los aprendizajes entre 87.5 % y 93.75 % un poco más altos que en cualquiera de los casos anteriores. Y como era de esperarse la característica de la memoria a largo plazo también se tiene presente con estos porcentajes en las conexiones sinápticas.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 100 % son excitatorias y el 0 % restante son inhibitorias, tendrá un desempeño favorable en la mayoría de los casos al realizar la actividad de sujetar de manera normal cualquier objeto de dimensión media-pequeña que le sea presentado, aunque como ya se mencionó, de manera biológica es poco probable que se pueda realizar este tipo de conexión.

## A.12. Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardio-respiratorio.


### PPCR Synaptic 10-90

Individuo = Paro Cardiorespiratorio

Neuronas excitatorias = 10 %

Neuronas inhibitorias = 90 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 10 % de las conexiones excitatorias y 90 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 0 %, en la figura A.162 se muestra el aprendizaje promedio en cada simulación, notamos que en ninguna simulación logró aprender.




**Figura A.162:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects\_10-90.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que todos se encuentran en **NA**. En la figura A.163 podemos verificar esta información donde el 100 % de las simulaciones tuvieron un comportamiento donde no se aprendió nada.


A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.

---




**Figura A.163:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_10-90.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.164, se observa que todas se sitúan en 0 respuestas correctas.



**Figura A.164:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_10-90.

En la figura A.165 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como todos se encuentran en el intervalo  $[0, 6.25]$ .



**Figura A.165:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR\_Objects\_10-90.

Para este caso no se realizó la clasificación del comportamiento de aprendizaje estable ya que en ninguna de las 251 simulaciones obtuvimos un aprendizaje mayor a 0.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorrespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 10 % de sus conexiones son excitatorias y 90 % inhibitorias, no obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio nulo, es decir nunca aprendió nada.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos que para todas únicamente se tiene un punto máximo donde se indica que se tiene el 100 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan siempre comportamientos en los que no aprende absolutamente nada y en consecuencia se tengan 0 respuestas correctas.


Con estos porcentajes en las conexiones sinápticas se obtuvieron los mismos resultados para un individuo sano y uno que sufrió un paro cardiorrespiratorio.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 10 % son excitatorias y el 90 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media- pequeña que le sea presentado.

### PPCR Synaptic 20-80


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 20 %  
Neuronas inhibitorias = 80 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 20 % de las conexiones excitatorias y 80 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 15.23 %, en la figura A.166 se muestra el aprendizaje promedio en cada simulación, notamos que en todas se tienen aprendizajes muy bajos, todos por debajo del 50 %.




**Figura A.166:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects\_20-80.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que la mayoría se encuentra en **NA**. En la figura A.167 podemos verificar esta información donde solo el 17 % de las simulaciones tuvieron un comportamiento estable.



**Figura A.167:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_20-80.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.168, se observa que de las 43 simulaciones que lograron aprender lo más que aprendieron fueron solo 2 respuestas correctas.



**Figura A.168:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_20-80.

En la figura A.169, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como todos se encuentran por debajo del 50% lo que explica que el aprendizaje promedio total sea tan bajo.

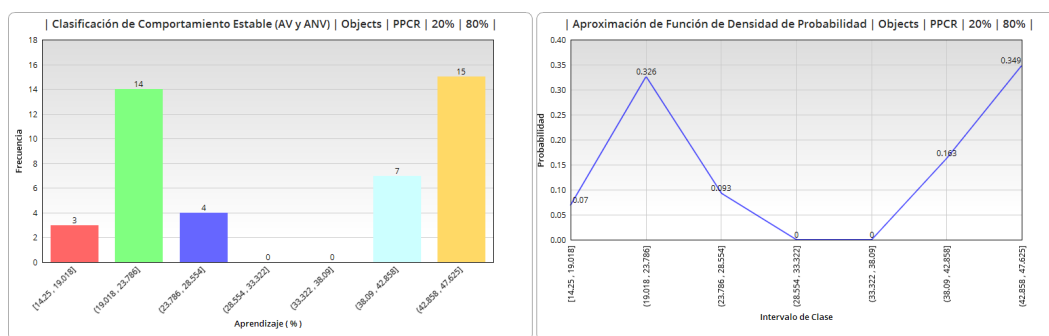
A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.169:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR\_Objects\_20-80.

Después de realizar la clasificación del comportamiento de aprendizaje, se realizó un histograma de frecuencias del aprendizaje obtenido en las simulaciones que fueron clasificadas como AV y ANV, es decir, únicamente de los comportamientos estables y con éste se obtuvo la función de densidad de probabilidad, los resultados obtenidos se muestran en la figura A.170.

Al analizar las gráficas de aprendizaje nos percatamos que el tiempo en que se mantiene la estabilidad es corto, es decir, siempre comienzan con muchas fluctuaciones y además el nivel de respuestas correctas es bajo, es por eso que se tienen aprendizajes por debajo del 50 %.



**Figura A.170:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR\_Objects\_20-80.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal, donde uno de los puntos máximos se da con un 32.6 % de probabilidad de que al

realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 19.01 % y 23.78 % y el otro con un 34.9 % de probabilidad de que se obtengan aprendizajes entre 42.85 % y 47.62 %. Se considera que en el primer intervalo se incluyen la mayoría de las simulaciones en las que se obtuvo únicamente una respuesta correcta, mientras que en el segundo se incluyen las que lograron aprender 2.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 20 % de sus conexiones son excitatorias y 80 % inhibitorias, tenemos que con esta relación del 20 %-80 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio bajo, y se obtuvieron solo en un 17 % de las simulaciones aprendizajes estables pero bajos.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación (figuras A.167, A.168 y A.120), observamos que para las 3 se tienen curvas en forma de J invertida, es decir, funciones decrecientes en las que la mayor probabilidad es para los comportamientos no válidos en los que no se logra aprender nada y en consecuencia se tengan 0 respuestas correctas.


Respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, estos fueron más bajos ya que la cantidad de simulaciones en las que no logró aprender es mayor, sin embargo, nos damos cuenta de que el comportamiento de las funciones de densidad de probabilidad en los histogramas de clasificación del comportamiento y el de las respuestas correctas es el mismo, por lo tanto, tienen la misma tendencia y esto lo corroboramos al notar que lo máximo que se pudo aprender fueron únicamente 2 respuestas correctas.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 20 % son excitatorias y el 80 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado ya que en ninguna simulación se aprendieron las 4 respuestas correctas y el número de simulaciones donde si aprendió es muy bajo.

### PPCR Synaptic 30-70


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 30 %  
Neuronas inhibitorias = 70 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 30 % de las conexiones excitatorias y 70 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 47.56 %, en la figura A.171 se muestra el aprendizaje promedio en cada simulación, que en éste caso aún es considerado bajo ya que la mayoría está por debajo del 80 %.




**Figura A.171:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects\_30-70.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados no son favorables ya que la mayoría se encuentra en **NA**. En la figura A.172 podemos verificar esta información donde el 74 % de las simulaciones tuvieron un comportamiento donde no se aprendió nada.



**Figura A.172:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_30-70.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.173, se observa que de las 64 simulaciones que lograron aprender se aprendieron 1, 2, 3 y en pocos casos las 4 respuestas correctas.



**Figura A.173:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_30-70.

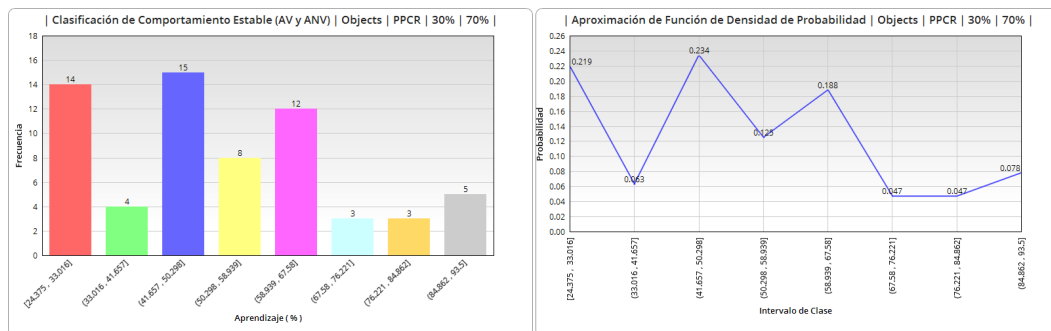
En la figura A.174, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra entre 25 % al 68.5 % .

A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.174:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR\_Objects\_30-70.

En la figura A.175, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. La mayoría están por debajo del 67.58 % debido a que se tienen comportamientos que inician con fluctuaciones y la estabilidad dura poco tiempo del aprendizaje.



**Figura A.175:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR\_Objects\_30-70.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva multimodal, donde uno de los puntos máximos se da con un 21.9% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 24.37 % y 33.01 % otro con un 23.4 % de probabilidad de que se obtengan aprendizajes entre 41.65 % y

50.29 % y el último con un 18.8 % de probabilidad de que los aprendizajes estén entre 58.93 % y 67.58 %, en comparación con los resultados del individuo sano con los mismos porcentajes en las conexiones sinápticas aquí se obtienen resultados más bajos.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 30 % de sus conexiones son excitatorias y 70 % inhibitorias, tenemos que con esta relación del 30 %-70 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables ya que en general se obtiene un aprendizaje promedio bajo, y se obtuvieron solo en un 25 % de las simulaciones aprendizajes válidos pero bajos.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, en las figuras A.172 y A.173 se presentan curvas con forma de J invertida, correspondientes a funciones decrecientes por lo que la probabilidad mayor se da para las simulaciones en las que no se logra aprender nada, o sea en las que se obtienen 0 respuestas correctas y en la figura A.125 observamos una curva multimodal, donde los puntos máximos se obtienen en los intervalos de aprendizaje entre 25 % y 31.25 %, 43.75 % a 50 % y de 62.5 % a 68.75 %, al tener tantas simulaciones con aprendizajes no válidos y observar esta gráfica nos damos cuenta que aunque sean comportamientos no válidos su aprendizaje promedio es alto y esto es debido a todas las fluctuaciones que se presentan en ellas.


Comparando respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, estos fueron más bajos ya que la cantidad de simulaciones en las que no logró aprender es mayor, sin embargo, nos damos cuenta de que el comportamiento de las funciones de densidad de probabilidad en los histogramas de clasificación del comportamiento y el de las respuestas correctas.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 30 % son excitatorias y el 70 % restante son inhibitorias, no tendrá un desempeño favorable al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado ya que a pesar de que si se lograron aprender las 4 respuestas correctas, los casos son demasiado pocos.

### PPCR Synaptic 40-60


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 40 %  
Neuronas inhibitorias = 60 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 40 % de las conexiones excitatorias y 60 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 68 %, en la figura A.176 se muestra el aprendizaje promedio en cada simulación, que en este caso es mejor que los anteriores pero aún bajo.




**Figura A.176:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects\_40-60.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV** podemos notar claramente que los resultados no son tan favorables ya que la mayoría se encuentra en **NA**, en la figura A.177 podemos verificar esta información donde sólo el 44 % de las simulaciones tuvieron un comportamiento estable y si lograron aprender.



**Figura A.177:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_40-60.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.178, se observa que de las 111 simulaciones que lograron aprender en 46 simulaciones se lograron aprender las 4 respuestas correctas.



**Figura A.178:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_40-60.


En la figura A.179, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra por encima del 50%.

A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.179:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR\_Objects\_40-60.

En la figura A.180 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Se tiene la mayor parte entre 88.27% a 95.125%, al igual que en el caso anterior el aprendizaje comienza con fluctuaciones pero logra estabilizarse y esto se mantiene la mayor parte del tiempo de aprendizaje, además que son más casos en los que logran aprender las 4 respuestas correctas.



**Figura A.180:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR\_Objects\_40-60.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva multimodal, donde uno de los puntos máximos se da con un 19.8% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se ob-

tengan comportamientos estables con un aprendizaje promedio entre 67.71 % y 74.56 % y el otro con un 27.9 % de probabilidad de que se obtengan aprendizajes entre 88.27 % y 95.125 % considerando que en el primero se incluyen las simulaciones en las que sólo logra aprender 3 respuestas correctas y en el segundo se incluyen las que aprenden las 4.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorrespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 40 % de sus conexiones son excitatorias y 60 % inhibitorias, tenemos que con esta relación del 40 %-60 % en conexiones excitatorias - inhibitorias no obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio no tan bajo, sin embargo, fueron muy pocos casos en los que logró aprender y aunque se pudieron aprender las 4 respuestas correctas no fueron los suficientes casos para considerar como bueno el aprendizaje con este tipo de conexiones.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.177 una curva en forma de J invertida donde la probabilidad mayor es para las simulaciones con comportamientos de aprendizaje no válidos. En la figura A.178 se presenta una curva no tan suave parecida a una curva en forma de U donde la probabilidad mayor es para obtener 0 respuestas correctas que era un resultado obvio debido al resultado de la figura A.177. Por último en la figura A.130 observamos una curva multimodal donde los puntos máximos se obtienen en los intervalos de aprendizaje entre 68.75 % y 75 % y de 87.5 % a 93.75 %, los dos son aprendizajes altos y al ver que la cantidad de simulaciones con aprendizajes no válidos es mayor concluimos que en estos comportamientos se obtienen aprendizajes altos debido a las fluctuaciones que se tienen.


Comparando respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, nuevamente estos fueron más bajos ya que la cantidad de simulaciones en las que no logró aprender es mayor y en el caso de la persona sana para estas conexiones sinápticas ya se tenían más simulaciones con comportamientos estables.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 40 % son excitatorias y el 60 % restante son inhibitorias, en general no se tendrá un desempeño favorable al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado, ya que siguen siendo más los casos con comportamientos de aprendizajes no válidos.

### PPCR Synaptic 50-50


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 50 %  
Neuronas inhibitorias = 50 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 50 % de las conexiones excitatorias y 50 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 79.5 %, en la figura A.181 se muestra el aprendizaje promedio en cada simulación, que en este caso es aún mejor que los anteriores.




**Figura A.181:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects\_50-50.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**. En la figura A.182 podemos verificar esta información donde sólo el 6% de las simulaciones tuvieron un comportamiento donde no logró aprender nada.



**Figura A.182:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_50-50.

Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.183, se observa que de las 236 simulaciones que lograron aprender en 144 simulaciones se lograron aprender las 4 respuestas correctas que son las que tenemos clasificadas como AV.




**Figura A.183:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_50-50.

En la figura A.184 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como la mayoría se encuentra entre 87.5 %


A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.

y 93.75 %.



**Figura A.184:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR\_Objects\_50-50.

En la figura A.185 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. La mayoría está por encima del 80 % debido a que la estabilidad se mantiene durante un tiempo de aprendizaje largo, sin embargo, se siguen teniendo varios casos en los que el aprendizaje comienza con fluctuaciones pero a pesar de eso logran aprender las 4 respuestas correctas.



**Figura A.185:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR\_Objects\_50-50.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva bimodal,

donde uno de los puntos máximos se da con un 16.9% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 66.1% y 69.77% y el otro con un 26.3% de probabilidad de que se obtengan aprendizajes entre 88.15% y 91.82%, considerando que en el primero se incluyen las simulaciones en las que logra aprender 3 respuestas correctas y en el segundo se incluyen las que aprenden las 4 como en el caso anterior.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 50% de sus conexiones son excitatorias y 50% inhibitorias, tenemos que con esta relación del 50%-50% en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio aceptable, y se obtuvieron solo en un 6% de las simulaciones aprendizajes no válidos.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.182 una curva donde las probabilidades mayores son para los comportamientos de aprendizaje válidos. En la figura A.183 se presenta una curva no tan suave parecida a una curva en forma de J, donde la probabilidad mayor es para obtener 4 respuestas correctas. Por último en la figura A.135 observamos una curva bimodal, donde los puntos máximos se obtienen en los intervalos de aprendizaje entre 62.5% y 68.75% y de 87.5% a 93.75%, los dos son aprendizajes altos y muy similares a los del caso anterior, sin embargo, en este caso la cantidad de simulaciones con aprendizajes no válidos es mucho menor.


Comparando respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, nuevamente estos fueron un poco más bajos y además todavía se tienen comportamientos que inician con fluctuaciones, por lo tanto, la característica de la memoria a largo plazo no se presenta en el total de los casos como para los resultados del individuo sano.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 50% son excitatorias y el 50% restante son inhibitorias, tendrá un desempeño favorable al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado, ya que el número de simulaciones con comportamientos no válidos es pequeño y en las que si logro aprender la mayoría obtuvo las 4 respuestas correctas.

### PPCR Synaptic 60-40


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 60 %  
Neuronas inhibitorias = 40 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 60 % de las conexiones excitatorias y 40 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 75.07 %, en la figura A.186 se muestra el aprendizaje promedio en cada simulación, que en este caso es un poco menor al del caso anterior pero mayor a los demás.




**Figura A.186:** Gráfica del aprendizaje promedio para cada simulación de PPCR.Objects.60-40.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**. En la figura A.187 podemos verificar esta información donde sólo el 14 % de las simulaciones tuvieron un comportamiento donde no logró aprender nada.



**Figura A.187:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_60-40.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.188, se observa que de las 214 simulaciones que lograron aprender en 120 simulaciones se lograron aprender las 4 respuestas correctas, el resto sólo aprendió 2 o 3.



**Figura A.188:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_60-40.


En la figura A.189, se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como casi todos están por encima del 50 %.

A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.189:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR\_Objects\_60-40.

En la figura A.190, se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Observamos que la mayor parte se concentra entre el 88.2% a 91.725% ya que se logran aprender las 4 respuestas correctas rápidamente, es decir la estabilidad se presenta durante casi todo el tiempo de aprendizaje, aún se tienen simulaciones que al inicio se tienen fluctuaciones.



**Figura A.190:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR\_Objects\_60-40.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva bimodal, donde uno de los puntos máximos se da con un 28.5% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan

comportamientos estables con un aprendizaje promedio entre 88.2% y 91.72%, resultados muy similares a los del caso anterior.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorrespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 60% de sus conexiones son excitatorias y 40% inhibitorias, tenemos que con esta relación del 60%-40% en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje menos favorables que en el caso anterior, ya que en general se obtiene un aprendizaje promedio un poco más bajo, y se obtuvieron más casos en que no logró aprender, sin embargo, en los casos que sí aprendió, fueron 3 o 4 respuestas correctas en la mayoría.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y del aprendizaje promedio en cada simulación, observamos en la figura A.187 una curva no simétrica donde las probabilidades mayores son para los comportamientos de aprendizaje válidos. En la figura A.188 se presenta una curva parecida a una curva en forma de U, donde la probabilidad mayor es para obtener 4 respuestas correctas. Por último en la figura A.140 observamos una curva bimodal, donde los puntos máximos se obtienen en los intervalos de aprendizaje entre 62.5% y 68.75% y de 87.5% a 93.75%, mismos intervalos obtenidos en el caso anterior, sin embargo, en este caso la cantidad de simulaciones con aprendizajes no válidos es un poco mayor.


Comparando los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, estos fueron un poco más bajos a pesar de obtener aprendizajes promedio altos.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 60% son excitatorias y el 40% restante son inhibitorias, tendrá un desempeño no tan favorable al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado.

### PPCR Synaptic 70-30


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 70 %  
Neuronas inhibitorias = 30 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 70 % de las conexiones excitatorias y 30 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 74.1 %, en la figura A.191 se muestra el aprendizaje promedio en cada simulación, que nuevamente en este caso es un poco menor al del caso anterior.




**Figura A.191:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects.70-30.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que a pesar de tener un aprendizaje promedio bajo la mayoría se encuentra en **ANV** y **AV**. En la figura A.192 podemos verificar esta información donde sólo 11 de las simulaciones tuvieron un comportamiento donde no logró aprender nada.



**Figura A.192:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_70-30.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.193, se observa que de las simulaciones que lograron aprender la mayoría logró 3 o 4 respuestas correctas.



**Figura A.193:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_70-30.

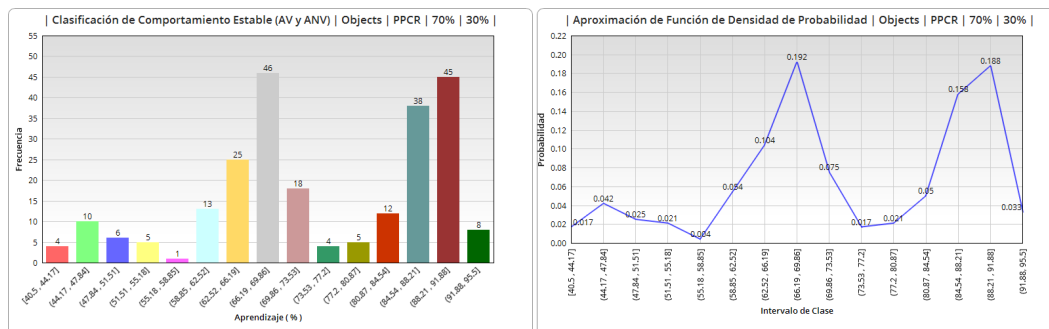
En la figura A.194 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como casi todos están por encima del 50 %.

A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.194:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Objects.70-30.

En la figura A.195 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Al analizar las gráficas observamos que en ninguno de los casos en los que se tiene un comportamiento estable se inicia con fluctuaciones antes de alcanzar la estabilidad, sin embargo, los aprendizajes que se encuentran menores al 70 % son los que solo alcanzan aprender 3 o 2 respuestas correctas, los demás son para los que si logran aprender las 4 respuestas correctas.



**Figura A.195:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Objects.70-30.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva bimodal donde uno de los puntos máximos se da con un 19.2 % de probabilidad de que al reali-

zar más simulaciones con estas características en las conexiones sinápticas se obtengan comportamientos estables con un aprendizaje promedio entre 66.19 % y 69.86 % que es donde se incluyen las simulaciones que logran aprender 3 respuestas correctas y se tiene un 18.8 % de probabilidad de que los aprendizajes promedio están entre 88.21 % y 91.88 %, donde se incluyen las que logran aprender las 4.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 70 % de sus conexiones son excitatorias y 30 % inhibitorias, tenemos que con esta relación del 70 %-30 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje no tan favorables, ya que en general se obtiene un aprendizaje promedio no tan alto, se obtuvieron solo en un 95 % de las simulaciones aprendizajes válidos pero no en todas se lograron aprender las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.192 una curva en forma de J, es decir, una función creciente donde las probabilidades mayores son para los comportamientos de aprendizaje válidos pero menores a la media. En la figura A.193 también se tiene una curva en forma de J donde la probabilidad mayor es para obtener 4 respuestas correctas. Por último en la figura A.145 observamos una curva bimodal, donde los puntos máximos se obtienen en los intervalos de aprendizaje entre 62.5 % y 68.75 % y de 87.5 % a 93.75 %, mismos intervalos obtenidos en los dos casos anteriores, sin embargo, en este caso la cantidad de simulaciones con aprendizajes no válidos es menor.


Comparando respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, estos también fueron un poco más bajos a pesar de obtener aprendizajes promedio altos, sin embargo, con estos porcentajes en las conexiones sinápticas ya se observó la presencia de la memoria a largo plazo.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 70 % son excitatorias y el 30 % restante son inhibitorias, tendrá un desempeño no tan favorable al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado ya que el número de simulaciones en las que aprendió las 4 respuestas correctas es menor aún que en las conexiones 50 % excitatorias - 50 % inhibitorias aún a pesar de que se tiene la característica de la memoria a largo plazo.

### PPCR Synaptic 80-20


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 80 %  
Neuronas inhibitorias = 20 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 80 % de las conexiones excitatorias y 20 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 75.68 %, en la figura A.196 se muestra el aprendizaje promedio en cada simulación, que es un poco menor incluso que el caso 50 %-50 %.




**Figura A.196:** Gráfica del aprendizaje promedio para cada simulación de PPCR.Objects.80-20.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV** y **ANV**, en la figura A.197 podemos verificar esta información donde sólo 5 de las simulaciones tuvieron un comportamiento donde no logró aprender nada.



**Figura A.197:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_80-20.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.198, se observa que de las simulaciones que lograron aprender la mayoría logró aprender 3 o 4 respuestas correctas.



**Figura A.198:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_80-20.


En la figura A.199 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar como casi todos están por encima del 62.50 %.

A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.199:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR\_Objects\_80-20.

En la figura A.200 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Al igual que en el caso anterior, en todos los casos el comportamiento estable se mantiene durante todo su tiempo de aprendizaje, sin embargo, los inferiores al 70 % son los que alcanzan aprender solo 2 o 3 respuestas correctas, los demás son para los que aprenden las 4 respuestas correctas.



**Figura A.200:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR\_Objects\_80-20.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable observamos que se tiene una curva bimodal, donde uno de los puntos máximos se da con un 21.5 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan

comportamientos estables con un aprendizaje promedio entre 67.31 % y 70.77 % y un 19.1 % de probabilidad de que los aprendizajes promedio están entre 84.61 % y 88.07 %, aprendizajes un poco menores a los del caso anterior pero con un mejor desempeño en el nivel de respuestas correctas.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorrespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 80 % de sus conexiones son excitatorias y 20 % inhibitorias, tenemos que con esta relación del 80 %-20 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables, ya que se obtuvieron muy pocos casos en que no logra aprender nada y de las que aprendieron la mayoría aprendió 3 o 4 respuestas correctas a pesar de tener un aprendizaje promedio no tan alto.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.197 una curva donde las probabilidades mayores son para los comportamientos de aprendizaje válidos. En la figura A.198 se tiene una curva en forma de J donde la probabilidad mayor es para obtener 4 respuestas correctas como en el caso anterior. En la figura A.150 observamos una curva bimodal donde los puntos máximos se obtienen en los intervalos de aprendizaje entre 62.5 % y 68.75 % y de 87.5 % a 93.75 %, mismos intervalos obtenidos en varios casos anteriores, sin embargo, también en este caso la cantidad de simulaciones con aprendizajes no válidos es menor.


Comparando respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, nuevamente estos fueron más bajos a pesar de obtener aprendizajes promedio altos.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 80 % son excitatorias y el 20 % restante son inhibitorias, tendrá un desempeño favorable en la mayoría de los casos al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media- pequeña que le sea presentado al tener memoria a largo plazo pero el nivel de respuesta no es tan bueno como en el caso 50 % excitatorias - 50 % inhibitorias.

### PPCR Synaptic 90-10


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 90 %  
Neuronas inhibitorias = 10 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 90 % de las conexiones excitatorias y 10 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 74.71 %, en la figura A.201 se muestra el aprendizaje promedio en cada simulación, que es un poco menor que los 4 anteriores.




**Figura A.201:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects\_90-10.

Sin embargo, al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV** y **ANV**. En la figura A.202 podemos verificar esta información donde sólo 1 de las simulaciones tuvo un comportamiento donde no logró aprender nada.



**Figura A.202:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_90-10.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.203, se observa que de las simulaciones que lograron aprender la mayoría logró aprender 4 respuestas correcta.



**Figura A.203:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_90-10.

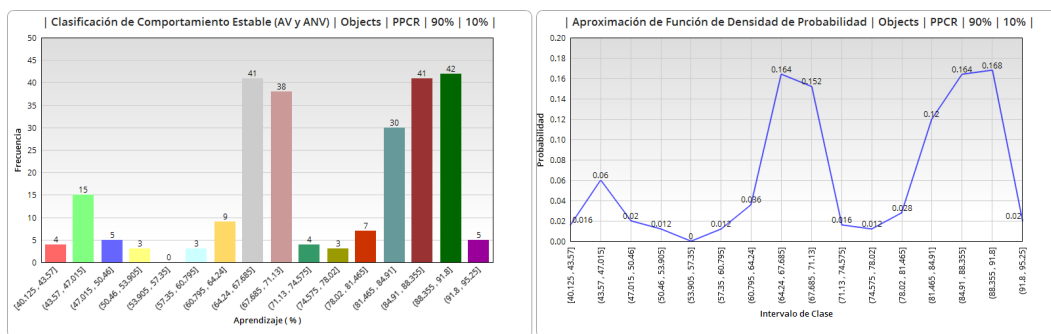
En la figura A.204 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar que la mayoría está entre 62.5 % a 68.5 % y de 81.25 % a 93.75 %.

A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.204:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Objects\_90-10.

En la figura A.205 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad para éste histograma. Aquí también en todos los casos el comportamiento estable se mantiene por más de la mitad del tiempo total de aprendizaje y al igual que en el caso anterior los que se encuentran menores al 71.13% son los que sólo alcanzan aprender 2 o 3 respuestas correctas, los demás son para los que si logran aprender las 4.



**Figura A.205:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Objects\_90-10.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva bimodal, donde uno de los puntos máximos se da con un 16.4% de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan

comportamientos estables con un aprendizaje promedio entre 64.24 % y 67.68 % y un 16.8 % de probabilidad de que los aprendizajes promedio están entre 88.35 % y 91.8 %, los aprendizajes del primer intervalo son un poco menores a los del caso anterior pero en el segundo tenemos valores más altos debido a que sólo 1 simulación obtuvo aprendizaje no válido y en las demás el nivel de respuestas correctas es bueno.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y poder sujetar sufriendo mioclonías cualquiera de estos objetos y donde el 90 % de sus conexiones son excitatorias y 10 % inhibitorias, tenemos que con esta relación del 90 %-10 % en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables, en general se obtuvo un aprendizaje promedio no tan alto, sin embargo, sólo en un caso no se logró aprender nada y en el resto se alcanzaron a aprender 3 o 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.202 una curva donde las probabilidades mayores son para los comportamientos de aprendizaje válidos. En la figura A.203 se tiene una curva en forma de J donde la probabilidad mayor es para obtener 4 respuestas correctas al igual que en el caso anterior y en la figura A.155 observamos una curva bimodal donde los puntos máximos se obtienen en los intervalos de aprendizaje entre 62.5 % y 68.75 % y de 81.25 % a 87.5 %, resultados similares a varios casos anteriores, sin embargo, también se obtienen aprendizajes superiores al 90 %.


Comparando respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, nuevamente estos fueron más bajos a pesar de obtener aprendizajes promedio altos, sin embargo, para este caso también se observó la presencia de la memoria a largo plazo.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 90 % son excitatorias y el 10 % restante son inhibitorias, tendrá un desempeño favorable en la mayoría de los casos al realizar la actividad de sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado.

### PPCR Synaptic 100-0


Individuo = Paro Cardiorespiratorio  
Neuronas excitatorias = 100 %  
Neuronas inhibitorias = 0 %

Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorespiratorio con 100 % de las conexiones excitatorias y 0 % inhibitorias se obtuvo un aprendizaje promedio total (entre las 251 simulaciones) de 91.12 %, en la figura A.206 se muestra el aprendizaje promedio en cada simulación, que en este caso es el más alto respecto a todos los anteriores.




**Figura A.206:** Gráfica del aprendizaje promedio para cada simulación de PPCR\_Objects\_100-0.

Al realizar la clasificación del comportamiento de aprendizaje obtenido de las gráficas, clasificado como **NA**, **AV** y **ANV**, podemos notar claramente que los resultados son favorables ya que la mayoría se encuentra en **AV**, en la figura A.207 podemos verificar esta información donde ninguna de las simulaciones tuvo un comportamiento donde no logró aprender nada.



**Figura A.207:** Histograma de frecuencias de la clasificación del comportamiento de aprendizaje para PPCR\_Objects\_100-0.


Por lo que al realizar el histograma de frecuencias del total de respuestas correctas que logró aprender en cada simulación, mismo que se presenta en la figura A.208, se observa que de las 251 simulaciones que lograron aprender, 156 logró aprender 4 respuestas correctas, el resto solo 3.



**Figura A.208:** Histograma de frecuencias para el total de respuestas correctas aprendidas en cada simulación para PPCR\_Objects\_100-0.

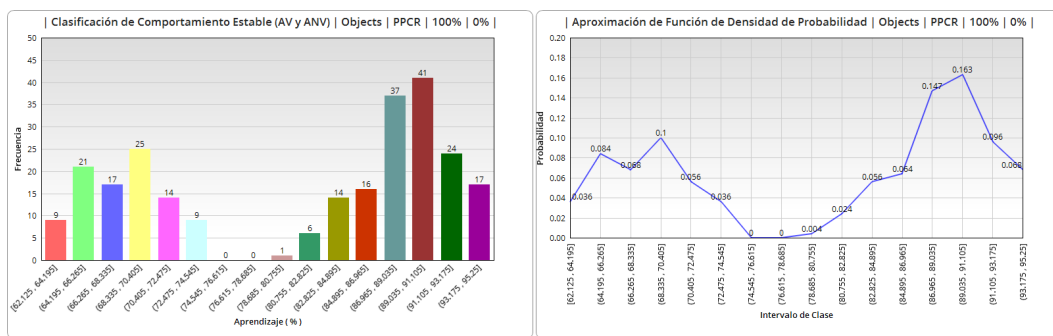
En la figura A.209 se muestra el histograma de frecuencias del aprendizaje promedio obtenido en cada simulación, podemos notar que la mayoría está entre 87.5% a 93.75%.

A.12 Resultados de RMCS para dificultad con tareas de motricidad fina de individuo que sufrió paro cardiorespiratorio.



**Figura A.209:** Histograma de frecuencias para el aprendizaje promedio obtenido en cada simulación para PPCR.Objects.100-0.

En la figura A.210 se muestra el histograma de frecuencias del aprendizaje clasificado como AV y ANV, es decir, únicamente de los comportamientos estables y la aproximación de la función de densidad de probabilidad de éste histograma. Al igual que en los casos anteriores en todos los casos el comportamiento estable se mantiene por más de la mitad del tiempo total de aprendizaje, sin embargo, los que se encuentran menores al 78 % son los que sólo alcanzan aprender 3 respuestas correctas, los demás son para los que si logran aprender las 4 respuestas correctas.



**Figura A.210:** Histograma de frecuencias para el aprendizaje promedio obtenido en las simulaciones con comportamiento de aprendizaje estable para PPCR.Objects.100-0.

Transformando a distribución de probabilidades el histograma de frecuencias del aprendizaje con comportamiento estable, observamos que se tiene una curva bimodal, donde uno de los puntos máximos se da con un 16.3 % de probabilidad de que al realizar más simulaciones con estas características en las conexiones sinápticas se obtengan com-

portamientos estables con un aprendizaje promedio entre 89.03% y 91.1%, intervalo donde se incluyen las simulaciones en las que se aprendieron las 4 respuestas correctas que en este caso es la mayoría.

Como conclusión general de la red neuronal para simular las conexiones neuronales de un individuo que sufrió un paro cardiorrespiratorio que realiza una actividad cotidiana como sujetar ciertos objetos de dimensión media-pequeña y sujetar sufriendo mioclonías con cualquiera de estos objetos y donde el 100% de sus conexiones son excitatorias y 0% inhibitorias, tenemos que con esta relación del 100%-0% en conexiones excitatorias - inhibitorias obtenemos resultados de aprendizaje favorables, ya que en general se obtiene un aprendizaje promedio bueno, y se obtuvieron en un 100% de las simulaciones aprendizajes estables y en la mayoría se obtuvieron las 4 respuestas correctas.

Al obtener la aproximación de la función de densidad de probabilidad de los histogramas de frecuencias de la clasificación del comportamiento de aprendizaje, de las respuestas correctas por simulación y el aprendizaje promedio en cada simulación, observamos en la figura A.207 una curva donde las probabilidades mayores son para los comportamientos de aprendizaje válidos de igual manera que varios de los casos anteriores. En la figura A.208 se tiene una curva en forma de J, es decir creciente donde la probabilidad mayor es para obtener 4 respuestas correctas y en la figura A.160 observamos una curva bimodal, donde uno de los puntos máximos se obtienen en los intervalos de aprendizaje entre 87.5% y 93.75% aprendizajes muy buenos debido a que todos tuvieron comportamientos estables.

Comparando respecto a los resultados de un individuo sano con estos mismos porcentajes en las conexiones sinápticas, nuevamente estos fueron más bajos a pesar de obtener aprendizajes promedio altos, ya que para una persona sana todas las simulaciones obtuvieron las 4 respuestas correctas y en este caso se tienen simulaciones donde aprendió sólo 3, además es importante señalar que aquí también se tiene la característica de la memoria a largo plazo.

Por lo tanto, hablando a nivel biológico, un individuo que genere conexiones sinápticas con las características de esta red neuronal donde un 100% son excitatorias y el 0% restante son inhibitorias, tendrá un desempeño favorable en la mayoría de los casos al realizar la actividad de sujetar sufriendo mioclonías con cualquier objeto de dimensión media-pequeña que le sea presentado, aunque de manera biológica es poco probable que se pueda realizar este tipo de conexión y menos en un individuo que sufrió una lesión cerebral ya que este tipo de daño debilita o elimina las conexiones sinápticas.

## A.13. Resultados de BP con diferencias temporales para dificultad al caminar

**PNormal con  $\alpha = 0.005$**

Individuo = Normal

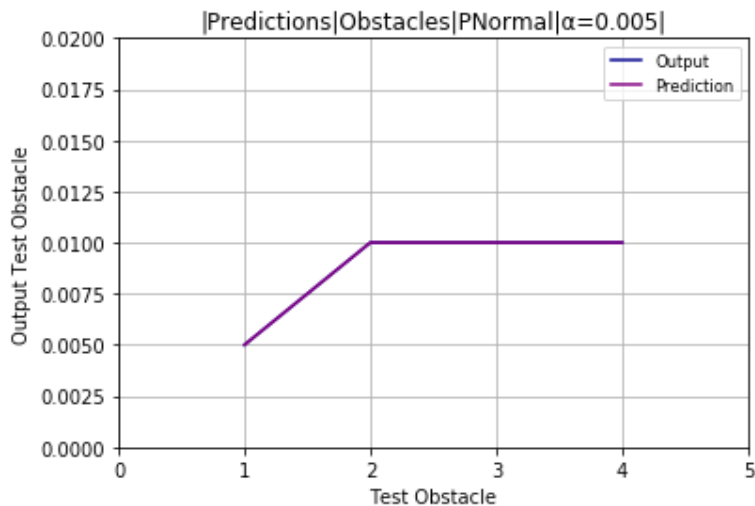
Para la simulación de las conexiones sinápticas de un individuo sano en el problema de dificultad al caminar se obtuvieron los siguientes resultados con el modelo BP con diferencias temporales, donde  $\alpha = 0.005$  para el cálculo de la salida deseada.

El objetivo a lograr en este problema es que aprenda a caminar de manera normal ante cualquier obstáculo que le sea presentado y permitiendo que se detenga un momento si se trata de un obstáculo de dimensión grande o tono agudo en caso de ser sonido.

Durante la etapa de entrenamiento se consiguió optimizar eficientemente el error de modo que en la época 0 tuvimos un error de  $1.03e^{08}$  y en la época 85 concluye el entrenamiento con un error de 0, por lo que se lograron obtener predicciones exactas.

Para obtener estos resultados fueron necesarias 40,000 conexiones sinápticas, donde al analizar los resultados del componente de memoria combinatoria Cj tenemos que del total de conexiones, 4,650 fueron excitatorias y 35,350 inhibitorias, es decir 11.625 % y 88.375 % respectivamente.

En la figura A.211 se muestran los resultados de las predicciones.



**Figura A.211:** Predicciones para PNormal\_Obstacles con  $\alpha = 0.005$ .

### PPCR con $\alpha = 0.005$

Individuo = Paro Cardiorespiratorio


Para la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio se obtuvieron los siguientes resultados.

En este caso el objetivo es que aprenda a caminar sufriendo mioclonías ante cualquier obstáculo de dimensión mediana-grande o tono medio-agudo para el caso del sonido y poder caminar normal al tener presente un obstáculo de dimensión pequeña o tono grave.

Al igual que en el caso anterior se consiguió optimizar eficientemente el error, de modo que en la época 0 tuvimos un error de  $1.07e^{08}$  y en la época 115 concluye el entrenamiento con un error de 0.

En este caso del total de conexiones, 4,298 fueron excitatorias y 35,702 inhibitorias, es decir 10.745 % y 89.255 % respectivamente.

En la figura A.212 se muestran los resultados de las predicciones obtenidas aquí.



**Figura A.212:** Predicciones para PPCR\_Obstacles con  $\alpha = 0.005$ .

Ahora se presentan los resultados para los mismos problemas pero con el cambio del valor de  $\alpha = 0.85535$ .

#### **PNormal con $\alpha = 0.85535$**


Individuo = Normal

Durante la etapa de entrenamiento nos dimos cuenta que al optimizar el error, éste se quedaba ciclado y no disminuía obteniendo muy malos resultados, por lo tanto se consiguió optimizar eficientemente el error disminuyendo el número de neuronas de la capa oculta a solo 100 ya que con un número mayor se tenía el mismo problema.

Por lo tanto, bajo estas condiciones obtuvimos un error de 8,249.77 al inicio del entrenamiento y en la época 49 concluye el entrenamiento con un error de 0, por lo que nuevamente se lograron predicciones exactas.

Para obtener estos resultados fueron necesarias 400 conexiones sinápticas donde al analizar los resultados del componente de memoria combinatoria Cj tenemos que del total de conexiones, 67 fueron excitatorias y 333 inhibitorias, es decir 16.75 % y 83.25 % respectivamente.

En la figura A.213 se muestran los resultados de las predicciones obtenidas.



**Figura A.213:** Predicciones para PNormal-Obstacles con  $\alpha = 0.85535$ .

### PPCR con $\alpha = 0.85535$

Individuo = Paro Cardiorespiratorio

En el caso de la simulación del individuo que sufrió el paro cardiorrespiratorio ocurrió el mismo problema con el error por lo que para corregirlo también se disminuyó el número de neuronas en la capa oculta a sólo 100.

Por lo tanto comenzamos el entrenamiento con un error de 7,559.361 y en la época 61 concluye el entrenamiento con un error de 0.

Del total de conexiones, 41 fueron excitatorias y 359 inhibitorias, es decir 10.25 % y 89.75 % respectivamente.

En la figura A.214 se muestran los resultados de las predicciones obtenidas.




Figura A.214: Predicciones para PPCR.Obstacles con  $\alpha = 0.85535$ .

## A.14. Resultados de BP con diferencias temporales para dificultad con tareas de motricidad fina

**PNormal**  $\alpha = 0.005$

Individuo = Normal

Para la simulación de las conexiones sinápticas de un individuo sano en el problema de dificultad con tareas de motricidad fina se obtuvieron los siguientes resultados con el modelo BP con diferencias temporales donde  $\alpha = 0.005$  para el cálculo de la salida deseada.

El objetivo en este problema es que aprenda a sujetar de manera normal cualquier objeto de dimensión media-pequeña que le sea presentado, a menos que se trate de un insecto pequeño, donde se permite que el objeto caiga al piso.

Durante la etapa de entrenamiento se consiguió optimizar eficientemente el error de modo que en la época 0 tuvimos un error de 65,169,428 y en la época 115 concluye el entrenamiento con un error de 0, por lo que nuevamente se logran predicciones exactas.

Para obtener estos resultados fueron necesarias 49,241 conexiones sinápticas donde al analizar los resultados del componente de memoria combinatoria Cj tenemos que del total de conexiones, 116 fueron excitatorias y 49,125 inhibitorias, es decir 0.24% y

99.76 % respectivamente.

En la figura A.215 se muestran los resultados de las predicciones, que como ya se mencionó fueron exactas debido a que se logró un error nulo.




Figura A.215: Predicciones para PNormal\_Objects con  $\alpha = 0.005$ .

### PPCR $\alpha = 0.005$

Individuo = Paro Cardiorespiratorio


En el caso de la simulación de las conexiones sinápticas de un individuo que sufrió un paro cardiorrespiratorio en el problema de dificultad con tareas de motricidad fina se obtuvieron los siguientes resultados.

Aquí el objetivo es que aprenda a sujetar sufriendo mioclonías cualquier objeto de dimensión media-pequeña que le sea presentado o dejando caer al piso un insecto pequeño.

Al inicio del entrenamiento obtuvimos un error de 34,242,792 y en la época 101 concluye el entrenamiento con un error de 0, por lo que nuestras predicciones también son exactas.

En este caso fueron necesarias 50,000 conexiones sinápticas donde al analizar los resultados del componente de memoria combinatoria  $C_j$  tenemos que del total de conexiones, 608 fueron excitatorias y 49,392 inhibitorias, es decir 1.216 % y 98.784 % respectivamente.

En la figura A.216 se muestran los resultados de estas predicciones.



**Figura A.216:** Predicciones para PPCR\_Objects con  $\alpha = 0.005$ .

Cambiando el valor de  $\alpha = 0.85535$ , al igual que en el problema anterior se disminuyó el número de neuronas de la capa oculta a 100, debido al mismo problema durante el entrenamiento.

### **PNormal** $\alpha = 0.85535$

Individuo = Normal

Bajo estas condiciones, en la época 0 tuvimos un error de 13,986.03 y en la época 62 concluye el entrenamiento con un error de 0, por lo que también se obtienen predicciones exactas.

Para obtener estos resultados fueron necesarias sólo 500 conexiones sinápticas, donde 7 de ellas fueron excitatorias y 493 inhibitorias, es decir, 1.4% y 98.6% respectivamente.

En la figura A.217 se muestran los resultados de las predicciones, que como ya se mencionó fueron exactas debido a que se logró un error nulo.




Figura A.217: Predicciones para PNormal\_Objects con  $\alpha = 0.85535$ .

### PPCR $\alpha = 0.85535$

Individuo = Paro Cardiorespiratorio

Para el individuo que sufrió un paro cardiorrespiratorio, obtuvimos al inicio del entrenamiento un error de 15,716.76 y en la época 61 concluye el entrenamiento con un error de 0.

Al igual que para el individuo normal con estas mismas condiciones, fueron necesarias únicamente 500 conexiones sinápticas donde al analizar los resultados del componente de memoria combinatoria Cj tenemos que del total de conexiones, 4 fueron excitatorias y 496 inhibitorias, es decir 0.8% y 99.2% respectivamente.

En la figura A.218 se muestran los resultados de las predicciones obtenidas.

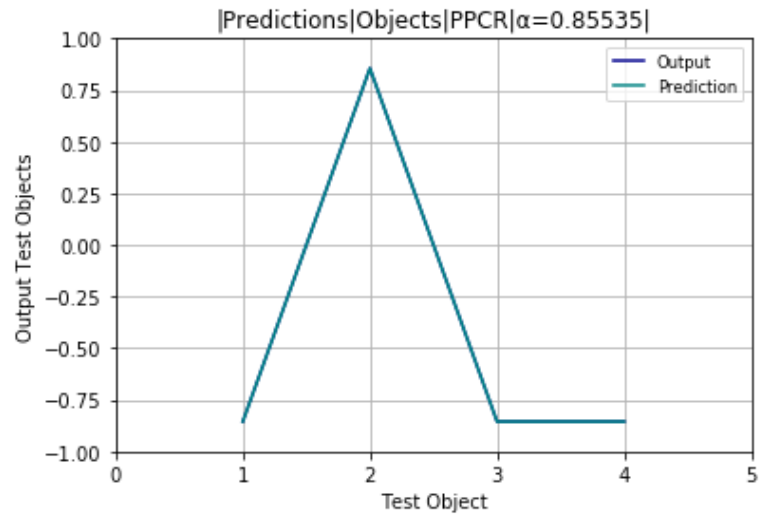


Figura A.218: Predicciones para PPCR\_Objects con  $\alpha = 0.85535$ .



# Bibliografía

---

- [1] Fidel Ramón, Armando Mansilla, and Amelia Rivera. Neurofisiología: para estudiantes de medicina. universidad nacional autónoma de méxico. facultad de medicina. <http://www.facmed.unam.mx/Libro-NeuroFisio/>. VII, VII, 1, 13, 15
- [2] Paramá Anabel. La acumulación de neuronas muertas en el cerebro agrava las enfermedades mentales. [https://www.tendencias21.net/La-acumulacion-de-neuronas-muertas-en-el-cerebro-agrava-las-enfermedades-mentales\\_a42719.html](https://www.tendencias21.net/La-acumulacion-de-neuronas-muertas-en-el-cerebro-agrava-las-enfermedades-mentales_a42719.html), 2006. VII, VII, 6
- [3] Carlos Arturo Cassiani-Miranda, Eduard Pérez-Aníbal, María Camila Vargas-Hernández, Edwin Darío Castro-Reyes, and Amira Fernanda Osorio. Brain injury after cardiac arrest. *Acta Neurol Colomb*, 29, 2013. VIII, VIII, 6
- [4] M Chalfie, JE Sulston, JG White, E Southgate, JN Thomson, and S Brenner. The neural circuit for touch sensitivity in caenorhabditis elegans. *Journal of Neuroscience*, 5(4):956–964, 1985. VIII, VIII
- [5] Allen Institute. Scientists are creating virtual simulations of the brain to better understand the real thing. *Brain Science*, 2019. VIII, VIII
- [6] Marat. M. Rvachev. Neuron as a reward-modulated combinatorial switch and a model of learning behavior. *The Journal of Neural Networks.*, 46:62–74, 2013. IX, IX, IX, 2, 3, 8, 37, 38, 40, 42, 44, 45, 51, 54, 55, 57, 59, 62, 68, 81, 105, 110, 111
- [7] Angela Bernardo. ¿cómo toma decisiones nuestro cerebro? <https://blogthinkbig.com/como-toma-decisiones-nuestro-cerebro>, 2016. 1
- [8] Gutiérrez Hernández Gloria del Carmen. Teoría de la toma de decisiones. definición, etapas y tipos. <https://www.gestiopolis.com/teoria-de-la-toma-de-decisiones-definicion-etapas-y-tipos/>. 2
- [9] Van Otterlo Martijn Wiering Marco. *Reinforcement Learning: State-of-Art*. Springer, 2012. 2, 24, 28, 31, 33, 34

## BIBLIOGRAFÍA

---

- [10] Yang Dan. Una sola neurona puede cambiar la actividad del cerebro entero. <https://www.hhmi.org/news/una-sola-neurona-puede-cambiar-la-actividad-del-cerebro-entero>, 2019. 5
- [11] OECD. *Understanding the Brain: The Birth of a Learning Science*. CERI, 2007. 5
- [12] Oxford University Press. *Diccionario de Medicina*. Editorial Complutense, 2007. 6
- [13] EPFL. Blue brain project. <https://www.epfl.ch/research/domains/bluebrain/>. 9, 37
- [14] SCIENTIFIC AMERICAN. Dos fármacos cutáneos regeneran neuronas dañadas por esclerosis múltiple. <https://www.scientificamerican.com/espanol/noticias/dos-farmacos-cutaneos-regeneran-neuronas-danadas-por-esclerosis-multiple/>. 11
- [15] Maria Talantova, Sara Sanz-Blasco, Xiaofei Zhang, Peng Xia, Mohd Waseem Akhtar, Shu ichi Okamoto, Gustavo Dziewczapolski, Tomohiro Nakamura, Gang Cao, Alexander E. Pratt, Yeon-Joo Kang, Shichun Tu, Elena Molokanova, Scott R. McKercher, Samuel Andrew Hires, Hagit Sason, David G. Stouffer, Matthew W. Buczynski, James P. Solomon, Sarah Michael, Evan T. Powers, Jeffery W. Kelly, Amanda Roberts, Gary Tong, Traci Fang-Newmeyer, James Parker, Emily A. Holland, Dongxian Zhang, Nobuki Nakanishi, H.-S. Vincent Chen, Herman Wolosker, Yuqiang Wang, Loren H. Parsons, Rajesh Ambasudhan, Eliezer Masliah, Stephen F. Heinemann, Juan C. Piña-Crespo, and Stuart A. Lipton.  $A\beta$  induces astrocytic glutamate release, extrasynaptic nmda receptor activation, and synaptic loss. *Proceedings of the National Academy of Sciences*, 2013. 11
- [16] Noelia Geribaldi-Doldán, Eugenia Flores-Giubi, Maribel Murillo-Carretero, Francisco García-Bernal, Manuel Carrasco, Antonio J. Macías-Sánchez, Jesús Domínguez-Riscart, Cristina Verástegui, Rosario Hernández-Galán, and Carmen Castro. 12-deoxyphorbols promote adult neurogenesis by inducing neural progenitor cell proliferation via pkc activation. *International Journal of Neuropsychopharmacology*, pages 1–14, 2016. 11
- [17] Sabyasachi Sircar. *Fundamentals of Medical Physiology*. Thieme Medical Publishers, 2012. 14, 15
- [18] Jason Bell. *Machine Learning: Hands-On for Developers and Technical Professionals*. WILEY, 2005. 16, 19, 22, 23
- [19] W.S. McCulloch W.Pitss. A logical calculus of the ideas immanent in neurons activity. *Bull. Math. Biophys.*, 5:115–133, 1943. 17, 18
- [20] Franck Rosenblatt. *Principles of neurodynamics: Perceptions and the theory of brain mechanism*. Spartan Books, 1962. 18, 19

- 
- [21] Javier Hugo Olivera. Evolución de controladores definidos por redes neuronales. universidad nacional de la plata. <https://core.ac.uk/download/pdf/15761131.pdf>. 19
- [22] Pérez Castaño Arnaldo. *Practical Artificial Intelligence Machine Learning, Bots, and Agent Solutions Using C*. APRESS, 2018. 24
- [23] Barto A. G. Sutton, R. S. *Reinforcement learning: an introduction*. Cambridge, MA: MIT Press, 1998. 26, 29, 30, 32, 33, 34
- [24] Lucian Busoniu Robert Babuska Bart De Schutter Damien Ernst. *Reinforcement Learning and dynamic programming using function approximators*. 2009. 28
- [25] Richard Bellman. Dynamic programming and stochastic control processes. *Information and Control*, 1(3):228–239, 1958. 30
- [26] Sayon Dutta. *Reinforcement Learning with TensorFlow*. Packt Publishing, 2018. 30, 31
- [27] Enrique Sucar. Métodos de inteligencia artificial. <https://ccc.inaoep.mx/esucar/Clases-MetIA/MetIA-15.pdf>. 30
- [28] Ming L. Becker S. Shitij K. Smith, A. Dopamine, prediction error and associative learning: A model-based account. *Computation in Neural Systems.*, 17:61–84, 2011.
- [29] P. W. Glimcher. Understanding dopamine and reinforcement learning: the dopamine reward prediction error hypothesis. *Proceedings of the National Academy of Sciences of the United States of America.*, 108(Suppl 3):15647–15654, 2011.
- [30] Hoogenraad C. Hotulainen, P. Actin in dendritic spines: connecting dynamics to function. *The Journal of Cell Biology.*, 189(4):619–629, 2010.
- [31] Brannon T. Mel B. Poirazi, P. Pyramidal neuron as two-layer neural network. *Neuron.*, 37(6):989–999, 2003.
- [32] Dayan P. Montague P. R. Schultz, W. A neural substrate of prediction and reward. *Science.*, 275:1593–1599, 1997.
- [33] W. Schultz. Predictive reward signal of dopamine neurons. *Journal of Neurophysiology.*, 80:1–27, 1998.
- [34] G.M. Courten-Myers. The human cerebral cortex: gender differences in structure and function. *j. neuropathol. Exp. Neurol.*, 58(3):217–226, 1999.
- [35] J. Olds and P. Milner. Positive reinforcement produced by electrical stimulation of septal area and other regions of rat brain. *J. Comp. Physiol. Psychol.*, 47:419–427, 1954.
-

## BIBLIOGRAFÍA

---

- [36] Spruston N. Pyramidal neurons: dendritic structure and synaptic integration. *Nat.Rev Neuroscience.*, 9:206–221, 2008.
- [37] J.H. Jessell T.M. Kandel, E.R.; Schwartz. Principios de neurociencia. *Madrid:McGraw Hill.*, 2001.
- [38] Sergio Muñoz Collado. El sistema nervioso somático (sns), anatomía y función. <https://www.psicoadictiva.com/blog/sistema-nervioso-somatico-sns-anatomia-funcion/>.