



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

INSTITUTO DE INVESTIGACIONES EN MATEMÁTICAS APLICADAS
Y EN SISTEMAS

CÓMPUTO CIENTÍFICO

APRENDIZAJE DE MÁQUINA EN FENÓMENOS
DINÁMICOS Y FRACTALES

T E S I S

QUE PARA OPTAR POR EL GRADO DE:
DOCTOR EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

PRESENTA:
RENÉ PÉREZ MOROYOQUI

TUTOR:
DRA. SUEMI RODRÍGUEZ ROMO

COMITÉ TUTOR:
DR. JAVIER GOMEZ CASTELLANOS
FACULTAD DE INGENIERÍA, UNAM

DRA. KATYA RODRÍGUEZ VÁZQUEZ
INSTITUTO DE INVESTIGACIONES EN MATEMÁTICAS APLICADAS Y EN SISTEMAS, UNAM

CD.MX. Junio 2023



Universidad Nacional
Autónoma de México

Biblioteca Central

Dirección General de Bibliotecas de la UNAM



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.

A mi familia y amigos por su apoyo en el trayecto.
A la Dra. Suemi Rodríguez Romo por su infinita paciencia.
Al Dr. Javier Gómez Castellanos por su interés y apoyo.
A todos mis tutores, por sus consejos y acertadas observaciones.
A Lulú por su ayuda, guía y aguante .

Reconocimientos

A la Universidad Nacional Autónoma de México por el desarrollo profesional que me ha brindado.

A los programas de la UNAM: PAPIIT IT102920 y UNAM CI2227, por su apoyo material

A CONACyT por el apoyo otorgado durante el desarrollo del presente trabajo.

Al Instituto de Investigaciones Matemáticas Aplicadas y Sistemas por ser mi casa durante mi estancia en el posgrado

Al Posgrado en Ciencia e Ingeniería de la Computación por la oportunidad otorgada y el apoyo incondicional.

Índice general

Índice de figuras	VII
Índice de tablas	XI
1. Aprendizaje de máquina en fenómenos dinámicos y fractales	1
1.1. Motivación	1
1.2. Introducción	1
1.3. Hipótesis	3
1.4. Objetivos	3
2. Fenómeno dinámico: Cinética de formación de hidratos de metano	7
2.1. Antecedentes	9
2.2. Modelo de aprendizaje profundo para imputar datos.	12
2.3. Ecuación empírica para la cinética de la formación de hidratos de metano.	16
2.4. Discusión y conclusiones preliminares	19
3. Fenómeno dinámico caso: Antenas fractales de Peano	25
3.1. Antecedentes	27
3.2. Simulaciones numéricas.	29
3.3. Resultados.	31
3.4. Peano 1	31
3.5. Ecuaciones para las frecuencias donde el $VSWR \leq 2$	35
3.6. Discusión y conclusiones preliminares	38
4. Fenómeno dinámico: Antena autoevitable	41
4.1. Antecedentes	41
4.2. Geometría de la SA-antena mediante el algoritmo de Backtracking.	42
4.3. Algoritmo genético aplicado en la obtención de una antena sintonizada	51
4.4. Discusión y conclusiones preliminares	53
5. Conclusiones	57

ÍNDICE GENERAL

6. Trabajo futuro	59
7. Resumen	61
A. Tablas de datos	63
A.1. Apéndice A	63
Bibliografía	69

Índice de figuras

2.1.	Molécula de metano	7
2.2.	Representación de la distribución de moléculas del hidrato de metano, en la parte central se muestra la molécula de metano rodeada por moléculas de agua	8
2.3.	Diagrama de la formación de hidratos en la superficie de una burbuja de gas. (1) burbuja de gas cubierta de hidratos por encima de la aguja de inyección de gas; (2) semiesfera cubierta de hidratos formada por una burbuja anterior; (3) capa de hidratos flotando sobre la fase acuosa; (4) salida de gas; (5) célula de alta presión; (6) fase gaseosa; (7) fase acuosa; (8) aguja de inyección de gas; (9) entrada de gas [1][2].	9
2.4.	Diagrama de flujo del método presentado en este trabajo.[3]	12
2.5.	Topología de la red neuronal artificial profunda utilizada en este trabajo.	13
2.6.	Velocidad experimental de formación de hidratos de metano para diferentes presiones a temperatura constante [1][2].	15
2.7.	Cinética experimental de formación de hidratos de metano. a) velocidad en función del índice de datos experimentales de la Tabla 1. b) velocidad en función de T y P . c) Datos experimentales normalizados o reescalados divididos en conjuntos de entrenamiento (azul) y de prueba (rojo). [1][2][3]	16
2.8.	RMC para las diferentes DNNs utilizadas en este trabajo. El punto rojo corresponde a DNN_{best} ya que su RMC es el mínimo [3].	17
2.9.	Predicciones de la red neuronal profunda DNN_{best} y datos experimentales de la Tabla 1. Superficie predicha por DNN_{best} y puntos experimentales en a), valores de velocidad predichos por DNN_{best} y datos experimentales en b), predicción de velocidad mediante DNN_{best} frente a velocidad experimental; una medida del rendimiento de DNN_{best} en c), y predicciones de DNN_{best} comparadas con datos experimentales solo para el conjunto de pruebas en d). [3]	18
2.10.	Programación genética; generaciones necesarias para diferentes poblaciones en los experimentos. El punto rojo corresponde al caso que produce la ecuación empírica reportada en este trabajo[3].	19

2.11. Velocidad dada por: los datos experimentales de la Tabla 1, la ecuación empírica y DNN_{best} , para cualquier índice experimental como el de la Tabla 2.1 [3].	19
2.12. Predicciones de ecuaciones empíricas y datos experimentales de la cinética de formación de hidratos de metano. Superficie predicha por la ecuación empírica y puntos experimentales en a), predicciones de la ecuación empírica e índice de datos experimentales como se indica en la Tabla 1 en b), y rendimiento de la ecuación empírica en c) [3].	20
2.13. Predicciones del límite de la velocidad constante por DNN_{best} [3]	21
2.14. A partir del modelo DNN: a) velocidad en función de la temperatura a presión constante y b) velocidad en función de la presión a temperatura constante. A partir de la ecuación empírica: c) velocidad en función de la temperatura a presión constante y d) velocidad en función de la presión a temperatura constante [3].	22
2.15. velocidad de crecimiento de los hidratos en función de la temperatura en K y la presión en MPa dada por: a) el modelo DNN y b) la ecuación empírica introducida en este trabajo. La línea roja muestra el estado de equilibrio dado por la referencia [4][3]	23
3.1. Puntos de alimentación $1/2S$ (rojo), $5/16S$ (cyan), $7/16S$ (magenta) y $1/8S$ (verde). a) Antena Peano, $i = 1$ (Peano_1), b) Antena Peano $i=2$ (Peano_2), and c) Antena Peano , $i = 3$ (Peano_3). [5]	30
3.2. Diagrama de flujo del método utilizado en este trabajo. El primer bloque (verde) es el módulo de caracterización de antenas Peano. El segundo bloque (marrón) es el módulo de frecuencia de resonancia. El tercer bloque (blanco) es el módulo de frecuencias tales que la $VSWR \leq 2$, y el cuarto bloque (naranja) es el módulo de solución.	32
3.3. Frecuencia de resonancia simulada para la antena Peano, $i=1$ (Peano_1) con punto de alimentación situado a 0.125 ($1/8$) veces la longitud S , $L < 0.10m$, y anchura de antena de 0.25 mm, 0.5 mm, y 1.0 mm [5]	33
3.4. Frecuencia de resonancia F en función de la longitud L para antenas Peano_1 con punto de alimentación situado a $0,125$ ($1/8$) de S para una anchura de antena de $0,25$ mm. [5].	34
3.5. Peano_1. Punto de alimentación situado a 0.125 (o $1/8$) veces S , $VSWR \leq 2$, curvas para las siguientes anchuras de antena: a) 0.25 mm, b) 0.5 mm, y c) 1.0 mm.	37
3.6. Curvas de frecuencia de resonancia de una antena de Peano iteración 3, con el punto de alimentación a $1/2S$ con un ancho de 0.5 mm. Los puntos corresponden a los datos usados para ajustar las funciones,	38

4.1. Curvas generadas por medio de Sistema-L, ambas son de 16cm de largo (a) generada totalmente aleatoria, (b) simétrica por rotación de 180 grados, la mitad de la curva es generada aleatoriamente. Los segmentos resltados en rojo son los puntos de alimentacion de la antena a la mitad de su estructura.	43
4.2. Diagrama de flujo del algoritmo de backtracking utilizado en este artículo.	44
4.3. Ejemplos de antenas con geometría autoevitables, en las Figuras correspondientes de a la impedancia, la linea azul describe la propiedad de resistencia y la linea naranja la reactancia, las Figuras a) L= 10 cm con su resistencia y reactancia, b) L= 20 cm con su resistencia y reactancia , c) L= 30 cm con su resistencia y reactancia, y d) L= 40 cm con su resistencia y reactancia.	45
4.4. a) Antena con L de 35 cm y en b) su correspondiente impedancia, c) Antena con L de 35 cm y en d) su correspondiente impedancia [5]. . . .	46
4.5. Datos de $\log(VSWR)$ de 5000 antenas con un tamaño L de 10cm (puntos en azul), se muestra en verde la curva resultado de la suma de senos $\log(VSWR) = a_1 \text{sen}(b_1 F + c_1) + a_2 \text{sen}(b_2 F + c_2) + a_3 \text{sen}(b_3 F + c_3) + a_4 \text{sen}(b_4 F + c_4) + a_5 \text{sen}(b_5 F + c_5) + a_6 \text{sen}(b_6 F + c_6) +$, además se muestra el mínimo local de la curva que se encuentra a 1929.73 MHz marcada con la linea en negro.	47
4.6. VSWR de 200 antenas con un tamaño L = 10cm: 4.6(a) se observa el agrupamineto por DBSCAN de datops con $VSWR \leq 2$ (rojo) 4.6(b) Datos de VSWR (azul), ajuste numérico que describe el comportamiento de los datos (verde), limite inicial y final de los datos $VSWR \leq 2$ (violeta) , puntos agrupados en el primero mínimo (rojo) y el mínimo calculado por medio de la curva de comportamiento (negro)	48
4.7. Datos de VSWR de 5000 antenas con un tamaño L de 20cm: 4.7(a) primer minimo destacado con la linea vertical (negro), 4.7(b) $VSWR \leq 2$ agrupados por medio de DBSCAN	49
4.8. Datos de simulación de VSWR de 5000 antenas con un tamaño L de 20cm , los límites de los rangos de datos de $VSWR \leq 2$ están delimitados por lineas de color purpura, en este caso los dos grupos obtenidos por medio de DBSCA se muestra en puntos de color rojo y cyan.	50
4.9. Datos de VSWR de 500 antenas con un tamaño L de 40cm: 4.9(a) 3 mínimos encontrados a lo largo de la curva, 4.9(b) detalles de la agrupación por medio de DBSCAN de los $VSWR \leq 2$ alrededor de los mínimos antes calculados.	51
4.10. Datos de VSWR de 5000 antenas con un tamaño L de 40 cm: 4.10(a) lineas de rangos donde el $VSWR \leq 2$, 4.10(b) datos de $VSWR \leq 2$ agrupados por medio de DBSCAN alrededor de los mínimos.	51
4.11. Resultado de la tabulación de los rangos de todas las simulaciones de antenas donde el $VSWR \leq 2$ [6]	52

4.12. Diagrama de flujo del algoritmo genético utilizado en este trabajo para producir la antena multibanda Figura 4.13. [6]	54
4.13. La antena SA generada por algoritmos genéticos (iteración 7773), a saber, la antena 7773, con una $VSWR \leq 2$ que transmite en dos frecuencias diferentes: 900MHz y 2400MHz, $L=0,23m$. El El cuadro resaltado en rojo es el punto de alimentación de la antena .El pequeño cuadrado negro está colocado sólo como referencia y tiene un tamaño de 1mm x 1mm [6].	55
4.14. VSWR de la antena 7773 en función de la frecuencia en la banda UHF. Se representan el valor mínimo de VSWR y el ancho de banda. La línea naranja corresponde a $VSWR=2$ [6].	56
4.15. Directividades de la antena-7773 en dos frecuencias, a) 900 MHz; b) 2400MHz. [6]	56

Índice de tablas

2.1. Datos experimentales de la velocidad de crecimiento de los hidratos de metano en función de la presión y la temperatura de las referencias [1][2].	14
3.1. Peano_1. Parámetros para las ecuaciones $VSWR < 2$, d igual a 0,25mm, 0,5mm y 1,0mm. El punto de alimentación se coloca a 0,125 (o 1/8) y 0,3125 (5/16) veces la longitud S .	35
3.2. Peano_1. Coeficientes polinómicos necesarios para calcular el ancho de banda en torno a la frecuencia central de forma que $VSWR \leq 2$. Para una anchura de antena de 0.25 mm, 0.5 mm y 1.0 mm, punto de alimentación situado a 0.125 (o 1/8) y 0.3125 (o 5/16) veces la longitud S .	36
4.1. Parámetros de las curvas que se ajustan a los límites de los rango obtenidas por medio de GPLEarn para las curvas en la Figura 4.11	53
A.1. Peano_1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.125 (1/8) de la longitud S , para tres anchuras de antena diferentes.	63
A.2. Peano_1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.3125 (o 5/16) veces la longitud S , para tres anchuras de antena diferentes.	64
A.3. Peano_1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.4375 (7/16) de la longitud S , para tres anchuras de antena diferentes.	65
A.4. Peano_1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.5 (o 1/2) veces la longitud S , para tres anchuras de antena diferentes.	66
A.5. Peano_1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.4375 (7/16) de la longitud S , para tres anchuras de antena diferentes.	67

Aprendizaje de máquina en fenómenos dinámicos y fractales

0.1. Motivación

Un fenómeno dinámico es un evento o proceso que cambia con el tiempo y está en constante evolución. En cualquier ciencia o campo, los fenómenos dinámicos pueden ser estudiados y analizados para entender su comportamiento y cómo afectan a otros sistemas o elementos relacionados. Algunos ejemplos de fenómenos dinámicos incluyen la economía, el clima, la población y los patrones de movimiento en la naturaleza. Algunos de estos fenómenos dinámicos como los sistemas climáticos, los comportamientos financieros, reacciones químicas etc, pueden exhibir patrones fractales. Para estudiar estos fenómenos, se propone el desarrollo de métodos que utilicen aprendizaje de máquina que sirvan para procesar datos obtenidos ya sea de forma experimental o por simulación computacional para describir sus comportamientos, obtener predicciones de los mismos fuera del rango experimental, o descubrir patrones.

0.2. Introducción

El aprendizaje de máquina es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos computacionales que permiten a las máquinas aprender a partir de datos y realizar tareas sin ser explícitamente programadas para hacerlo. Es una rama de la inteligencia artificial basada en la idea de que los sistemas pueden aprender de los datos, identificar patrones y tomar decisiones con una intervención humana mínima. Tiene una serie de aplicaciones importantes en diversos campos, entre ellas:

1. Sanidad: los algoritmos de aprendizaje automático pueden utilizarse para predecir la probabilidad de ciertas enfermedades, identificar posibles efectos secundarios de los medicamentos y hacer recomendaciones de tratamiento.
2. Finanzas: el aprendizaje automático puede utilizarse para detectar transacciones

fraudulentas con tarjetas de crédito, predecir el precio de las acciones e identificar posibles oportunidades de inversión.

3. Fabricación: el aprendizaje automático puede utilizarse para optimizar los procesos de producción, predecir fallos en los equipos y mejorar la gestión de la cadena de suministro.
4. Atención al cliente: el aprendizaje automático puede utilizarse para mejorar la eficiencia de las operaciones de atención al cliente prediciendo qué consultas de los clientes pueden requerir una asistencia más compleja y dirigiéndolas al agente adecuado.

En general, la importancia del aprendizaje automático radica en su capacidad para analizar conjuntos de datos grandes y complejos, identificar patrones y tendencias que podrían no ser evidentes de inmediato para los humanos, y tomar decisiones basadas en esos conocimientos. Esto puede ayudar a las organizaciones a tomar decisiones más informadas, mejorar las operaciones e impulsar el crecimiento del negocio.

Los datos actualmente son un activo importante y valioso de grupos científicos, empresas y gobiernos. Con el auge del aprendizaje de máquina estos datos son vitales para el desarrollo de nuevos métodos, algoritmos, aplicaciones y usos del saber científico en distintos ámbitos de la sociedad.

En medicina se incrementan los estudios del uso de nuevas moléculas en varios padecimientos y enfermedades usando inteligencia artificial para acotar la enorme cantidad de moléculas candidatas. Un ejemplo de caso de éxito es el uso de nuevas moléculas para su aplicación como agentes antibióticos.

En el ámbito del desarrollo de materiales para aplicaciones industriales se ha utilizado aprendizaje de máquina para obtener nuevas aleaciones. Las combinaciones de nuevas aleaciones con decenas de elementos se calcula que puede alcanzar aproximadamente 10^{78} combinaciones. Un número de aleaciones para investigar demasiado grande por lo que se necesita acotarlo para ahorrar tiempo y esfuerzo. La mayoría de las aleaciones conocidas se han desarrollado por el método experimental de prueba y error ayudándose con el conocimiento acumulado de las propiedades físicas y químicas de los materiales. En concreto se puede hablar de nuevas aleaciones comparadas con el *invar*¹, cuyos usos se extienden a diseño de instrumentos de precisión, relojes, mecánica de ópticas de telescopio entre otros, Rao et al. [7] han generado dos aleaciones por medio de IA que igualan al invar y otras dos tiene el coeficiente de expansión térmica más bajo.

¹Se trata de una aleación que contiene un 64% de hierro, un 36% de níquel con pequeñas proporciones de carbono, manganeso y cromo. Tiene un bajo coeficiente de expansión desde temperaturas criogénicas hasta los 260 °C y se utiliza en instrumentos de precisión, fue creado por el físico suizo Charles Édouard Guillaume y por ello fue galardonado con el premio nobel de física del año de 1920.

En este trabajo se abordó el uso de aprendizaje de máquina junto con el cómputo científico para su exploración en la aplicación de dos temas centrales. El primer tema es el uso de estas herramientas para imputar datos no explorados de un experimento acerca de la velocidad de formación de hidratos de metano, sobre estos datos imputados se obtiene mediante programación genética una formula para predecir dicha velocidad. El segundo tema se centra sobre antenas fractales, se han calculado por medio de cómputo científico las propiedades electromagnéticas de múltiples antenas con una geometría basada en la curva fractal de Peano, analizando los datos obtenidos y utilizando nuevamente programación genética, se muestran las relaciones en las propiedades eléctricas mediante formulas matemáticas, esto en el estudio de una estructura de antenas fija. Después se aborda el estudio de otro tipo de antena con estructura variable para que cubra requerimientos específicos de diseño, aplicando algoritmos genéticos y métodos numéricos electromagnéticos.

0.3. Hipótesis

El aprendizaje de máquina es una herramienta poderosa en la investigación que permite estudiar conjuntos de datos obtenidos de fenómenos dinámicos para modelar relaciones entre los mismos y poder ser aplicados a predicciones de su comportamiento. Es posible entrenar modelos para predecir el comportamiento futuro de un sistema dinámico basándose en su historial así como identificar patrones que ayuden a comprender el funcionamiento o la relación de estos fenómenos.

0.4. Objetivos

- Se propondrá un método que usa inteligencia artificial (IA) para la imputación ¹ de datos dispersos experimentales sobre la velocidad de formación de hidratos de metano (HM).
- Se desarrollará el software necesario para el uso de algoritmos genéticos en la obtención de relaciones matemáticas de datos tanto de la velocidad de formación de hidrato de metano, así como de las propiedades electromagnéticas de antenas fractales.
- Se obtendrán relaciones matemáticas de datos obtenidos por medio de cómputo científico de antenas fractales deterministas y estocásticas para la predicción de su comportamiento y mejorar su eficiencia energética.

En esta tesis doctoral, se desarrolla un estudio en tres campos distintos. En el primer capítulo, se despliega una innovadora aplicación de las redes neuronales para la

¹La imputación es un método matemático para reemplazar los valores faltantes en un conjunto de datos. Dejar estos valores faltantes puede causar problemas en los análisis posteriores y puede dar lugar a conclusiones sesgadas o incorrectas

imputación de datos en fenómenos dinámicos. Con la eficacia y precisión inherentes a estas poderosas herramientas de aprendizaje automático, se logra generar una ecuación que describe acertadamente el comportamiento del fenómeno estudiado. Esta aproximación computacional a la resolución de problemas de imputación de datos ofrece un punto de partida sólido para investigaciones futuras en el campo.

El segundo capítulo nos lleva al mundo de las antenas fractales, centrándose en particular en la antena de Peano. La geometría única de esta antena es estudiada en profundidad, y se emplean técnicas de cómputo científico para calcular sus propiedades de manera precisa. El análisis no se detiene allí, ya que se emplean algoritmos genéticos para obtener ecuaciones que describen las propiedades estudiadas. Este estudio integral de las antenas fractales de Peano proporciona un marco valioso para futuras investigaciones y aplicaciones en este campo.

Finalmente, en el tercer capítulo, se realiza un análisis riguroso de las antenas con estructuras pseudoaleatorias. Utilizando un enfoque similar al del capítulo anterior, se estudian las características de estas antenas y se obtienen ecuaciones que describen sus propiedades. Este capítulo no solo proporciona una valiosa contribución al campo del análisis de antenas, sino que también establece un puente sólido entre el análisis teórico y las aplicaciones prácticas.

El cuarto capítulo marca un punto de reflexión crucial, ya que se recogen y sintetizan las conclusiones de los capítulos anteriores. Se evalúan y destacan los logros obtenidos en cada capítulo, proporcionando una visión integrada de las contribuciones a la teoría y la práctica que resultan de este estudio. Este capítulo no solo sirve para resumir los resultados y discutir las implicaciones, sino que también proporciona una perspectiva sobre las limitaciones del estudio y posibles direcciones para futuras investigaciones.

El último capítulo, como es típico en los trabajos de investigación, se dedica a contemplar y describir posibles direcciones para futuros trabajos de investigación. A la luz de los hallazgos y conclusiones presentados en los capítulos anteriores, se esbozan varias oportunidades prometedoras para futuras investigaciones. Aquí, se profundiza en cómo la técnica de imputación desarrollada a lo largo de este trabajo podría aplicarse a nuevos conjuntos de datos experimentales, así como la posibilidad de extender las técnicas de estudio de antenas a otros tipos de estructuras, como antenas con estructuras de curvas fractales de Wunderlich, Hilbert y Moore.

Además, se sugiere la mejora de los resultados actuales acercándolos más a la realidad a través de la incorporación de sustratos en los modelos de antena. Este capítulo pone de manifiesto la naturaleza cíclica de la investigación científica, donde cada respuesta descubierta abre una serie de nuevas preguntas y posibilidades.

Fenómeno dinámico: Cinética de formación de hidratos de metano

En este capítulo, se estudió el proceso de creación de hidratos de metano, poniendo un enfoque especial en su velocidad de formación. Los datos experimentales fueron sometidos a un tratamiento utilizando técnicas de redes neuronales. Este procedimiento ayudo a imputar datos que no se encontraban en el conjunto de datos iniciales.

Posteriormente, el foco se puso en la obtención de una ecuación descriptiva del comportamiento de la velocidad de formación de los hidratos de metano. En este proceso, se emplearon algoritmos genéticos, una metodología inspirada en la teoría de la evolución natural, que permitió identificar la mejor ecuación para describir los datos experimentales.

Dentro de los compuestos llamados hidrocarburos, existe una serie que anteriormente se denominaba parafinas por su poca reactividad química (del latín *parum affinis* : poca actividad), actualmente estos compuestos conforme a la UIPAC ¹ reciben el nombre de alcanos, la formula química general de esta familia es C_nH_{2n+2} . El metano es el hidrocarburo más simple de la serie de los alcanos, su formula química es CH_4 ,en la figura 2.1 se muestra la estructura esquemática de su molécula [8].




Figura 1.1: Molécula de metano

Una característica importante del metano es que su calor de combustión es muy elevado, por lo que es un combustible muy apreciado. Se obtiene principalmente del

¹International Union of Pure and Applied Chemistry, es la autoridad reconocida para el desarrollo de los estándares para la denominación de compuestos químicos.

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO

gas natural de los yacimientos petroleros, y aparece también como gas grisú dentro de los yacimientos de carbón de hulla, aunque de forma muy secundaria y en este caso indeseable, ya que al extraer el carbón si este gas aparece se puede mezclar con el oxígeno del ambiente creando una mezcla explosiva [8]. La descomposición química de materia orgánica, también puede ser una fuente de metano aunque en menor escala que las extracciones petroleras. Finalmente, otra fuente potencial de obtención es en forma de hidratos de metano (HM), en la Figura 2.2 se muestra su estructura molecular.




Figura 1.2: Representación de la distribución de moléculas del hidrato de metano, en la parte central se muestra la molécula de metano rodeada por moléculas de agua

Estos HM se obtiene principalmente de las profundidades de los océanos en depósitos que se encuentran a mucha profundidad, debido a las características que se necesitan para su formación y conservación. A saber, el metano se produce de la descomposición de la materia orgánica, la materia cae a las profundidades oceánicas desde la superficie, en el fondo marino al producirse el metano éste se encuentra en condiciones físicas muy peculiares, baja temperatura y alta presión. Bajo estas condiciones la molécula de metano puede quedar atrapada entre moléculas de agua esto se da sin una interacción química ya que el agua y el metano no reaccionan entre sí, pero el hielo resultante contiene moléculas de agua que rodean a la molécula de metano. Los HM son un recurso potencial de energía [9], ya que hay una importante acumulación de dichos hidratos generados a lo largo de eones en los fondos marinos. Es por ello que los estudios de su formación son muy importantes para modelar la generación de yacimientos para exploración y explotación.

En la primera parte de este trabajo, se aplicaron redes neuronales para la imputación de datos, experimentando con distintos tipos de funciones de activación, parámetros de configuración, y algoritmos de entrenamiento, los datos originales se obtuvieron de una serie de experimentos [1][2] de hidratos de metano. Se generaron datos nuevos con estas redes y sobre estos, se utilizó programación dinámica para la obtención de fórmulas que describen su comportamiento y que posteriormente se evalúan para encontrar la mejor aproximación a los datos experimentales.




Figura 1.3: Diagrama de la formación de hidratos en la superficie de una burbuja de gas. (1) burbuja de gas cubierta de hidratos por encima de la aguja de inyección de gas; (2) semiesfera cubierta de hidratos formada por una burbuja anterior; (3) capa de hidratos flotando sobre la fase acuosa; (4) salida de gas; (5) célula de alta presión; (6) fase gaseosa; (7) fase acuosa; (8) aguja de inyección de gas; (9) entrada de gas [1][2].

1.1. Antecedentes

En este desarrollo, se propuso el uso de inteligencia artificial para estudiar la cinética de crecimiento del hidrato de metano. Algunas de las principales aplicaciones de IA es en el reconocimiento de patrones, ya sea en imágenes o audio (por ejemplo para reconocimiento facial de seguridad o reconocimiento de comandos de voz). La principal diferencia entre estas aplicaciones y en el desarrollo propuesto aquí, es el tamaño del conjunto de datos. Mientras que, para el uso de imágenes y audios se pueden disponer de millones de datos, el experimento en que se fundamenta esta parte del trabajo solo se disponen de 49 datos (r, t, P) que son reportados por Ma et al. y Sun et al. [1] y [2].

Los hidratos de gas (HG) son cristales formados por moléculas de agua y algún gas, en el caso del presente trabajo el gas es CH_4 por lo que se tiene hidrato de metano (HM). En particular, el HM se comporta en la naturaleza como el hielo, pero contiene grandes cantidades de metano. No es estable a la presión y temperatura normales del nivel del mar.

Se han realizado estudios sobre la cinética de formación del HG; véanse por ejemplo, las referencias [10–13]. La cinética de la formación de HG está controlada por dos pasos: el tiempo necesario para que los núcleos de hidrato alcancen el tamaño crítico estable y el crecimiento de los cristales de hidrato de gas. Este primer paso implica una nucleación estocástica y no puede predecirse con precisión [13]. Este trabajo se centra en el segundo paso.

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO

Los experimentos de Ma et al. y Sun et al. [1][2] son muy importantes para esta investigación; en ellos se midió la velocidad de crecimiento de los hidratos. En estos experimentos, el hidrato se formó en la interfaz gas-líquido sobre una burbuja de gas suspendida en una fase acuosa ver la Figura 2.3 para el armado experimental. Nótese que estos experimentos no contienen todas las situaciones de crecimiento del hidrato.

Las redes neuronales artificiales son modelos computacionales (IA) que consisten de un conjunto de unidades llamadas neuronas artificiales conectadas para transmitir señales. La información de entrada atraviesa la red neuronal, donde se somete a diversas operaciones que producen los valores de salida. Se propone una estrategia para utilizar redes neuronales profundas (DNN), una red neuronal artificial (ANN) con más de una capa oculta, educada por todos los datos experimentales disponibles en la literatura para construir una nueva base de datos, seguida de programación genética, para proponer una nueva ecuación cinética empírica de formación de HM.

Aunque la programación genética realiza una gran variedad de tareas, gplearn se limita a resolver problemas de regresión simbólica (RS). La RS es una técnica de aprendizaje automático que identifica la expresión matemática subyacente que mejor describe una relación. La RS comienza por construir una población de relaciones de fórmulas aleatorias iniciales para representar una relación entre variables independientes conocidas y sus objetivos de variables dependientes para predecir nuevos datos. Luego, cada generación sucesiva evoluciona seleccionando los individuos más aptos de la población para someterlos a operaciones genéticas.

Una de las principales contribuciones de este trabajo es una ecuación empírica para la velocidad de crecimiento del CH_2H_2O en términos de T y P [3]. Por otra parte, utilizando el modelo DNN podemos proporcionar datos (velocidad, T, P) que reproducen los experimentos con gran precisión. Aunque ambos modelos pueden predecir velocidades para diferentes temperaturas y presiones, el primer modelo matemático (la ecuación) es una herramienta analítica que contiene toda la información relacionada con la cinética de formación de HM. En cambio, el segundo modelo (el DNN) es un modelo computacional con hiperparámetros a determinar. Además, aunque las relaciones de RNA (Redes Neuronales Artificiales RNA) detectan implícitamente complejas relaciones no lineales entre variables independientes y dependientes, son cajas negras.

Aunque la ecuación empírica propuesta en este trabajo proporciona una expresión sencilla, esta ecuación tiene un error más significativo que los valores dados por un modelo DNN que implica un número importante de hiperparámetros. No obstante, ambos enfoques son adecuados para ser utilizados con diferentes objetivos. La importancia de la nueva ecuación radica, entre otras cosas, en la necesidad de avanzar en los modelos del mecanismo de reacción del crecimiento del cristal de HM en la superficie de la burbuja, ya que esto no puede hacerse con el modelo DNN. Mohammadi et al. [14–16]

introdujeron un modelo que utiliza algoritmos de redes neuronales artificiales (RNA) feed-forward como antecedente de este trabajo. Además, sus predicciones se ajustan a los datos experimentales con una precisión aceptable, lo que demuestra la exactitud de los métodos de IA como herramientas de predicción.

En la literatura se ha propuesto un mecanismo de crecimiento de los hidratos, véase por ejemplo las referencias [17] y [18]. Este mecanismo consiste en la formación de un hidrato estequiométrico básico a través de una reacción de adsorción de moléculas de gas en las cavidades enlazadas vacías del hidrato básico. Long y Sloan [19] propusieron que las moléculas de gas (G) disueltas en el agua forman agrupaciones inestables, con algunas moléculas de gas que rodean a cada molécula de agua; a saber, $H_2O + \beta GG\beta - H_2O$. Los clusters están totalmente ocupados por G, con todas las cavidades enlazadas vacías, se forman a través de la asociación de cúmulos básicos inestables. En, o cerca de, el equilibrio, es aceptable utilizar la teoría de absorción de Langmuir para describir la carga de las cavidades enlazadas por moléculas de gas. Este mecanismo de absorción es adecuado para explicar la composición no estequiométrica de los hidratos [20]. Algunos modelos termodinámicos que estudian la formación de hidratos son diversos ajustes del modelo de van der Waals-Platteeuw [21].

La expresión más general para la cinética de formación de HM de las referencias [1] y [2] es velocidad=función(P,T), que sólo implica que la energía media de la reacción y la probabilidad de que las moléculas colisionen bastan para definir la velocidad. Normalmente, se utiliza una hipótesis estándar; estos dos factores son en cierto modo independientes, y podemos considerar que la velocidad = función(P) función(T). Todas las cinéticas de formación de hidratos de metano que aparecen en la literatura [1][2] asumen esta hipótesis. Esta interpretación implica un grado de simplicidad subyacente a la reacción que los datos experimentales no necesariamente respaldan. En este trabajo, no se asume ninguna hipótesis cuando se realizan cálculos, no descartamos ninguna posibilidad para velocidad = función(P,T), incluso el caso de velocidad = función(P)función(T), siempre que esté respaldado por los datos experimentales.

En la Figura 2.3, se muestra el hidrato formado en la interfase gas-líquido de una burbuja de CH_4 suspendida en una fase acuosa. Una cámara de vídeo grabó la cinética de formación y por medio de software específico, se obtuvo la velocidad media de crecimiento de hidratos (r, expresada en mm^2/s). Se obtuvo también el T para una temperatura (Kelvin) y P una presión de metano (MPa) como se indican en las referencias [1][2]. Utilizamos este pequeño conjunto de datos como semilla para educar un modelo DNN y producir una nueva base de datos. Finalmente, se proporciona una nueva ecuación cinética empírica de crecimiento de los hidratos de metano a través de la programación genética.

1.2. Modelo de aprendizaje profundo para imputar datos.

Los conjuntos de datos científicos de los experimentos suelen ser pequeños y difíciles de de recopilar. En estos casos, los modelos de aprendizaje automático (ML) pueden perder la capacidad de aprender de los datos, lo que da lugar a un mal rendimiento de las predicciones. Para proponer la cinética de reacción del crecimiento del hidrato de metano en la superficie de una burbuja, se inició con los datos experimentales utilizados para construir un modelo de aprendizaje, es decir, los datos de la referencia [1][2].




Figura 1.4: Diagrama de flujo del método presentado en este trabajo.[3]

De la referencia, [1],[2], se obtiene el conjunto completo de velocidades de crecimiento de los hidratos de metano para construir la Tabla 2.1 de este trabajo. Esta tabla organiza los datos como sigue; los valores (velocidad,P,T) están ordenados y etiquetados por un índice N_x (x es el índice de datos experimentales). En la Figura 2.6 se puede ver la velocidad experimental como función de la presión a algunas temperaturas

constantes.

Se utilizó un nuevo conjunto de datos generado por una DNN para realizar la programación genética y proporcionar una nueva expresión empírica adecuada para velocidad = función(P,T). La topología de la DNN utilizada aquí se muestra en la Figura 2.5. Se proponen dos neuronas de entrada, una para la temperatura normalizada y otra para la presión normalizada, una neurona de salida para la velocidad normalizada, y cinco capas ocultas de 100 neuronas. Este número de capas y neuronas por capa, fueron elegidos por previos experimentos computacionales con datos de prueba.




Figura 1.5: Topología de la red neuronal artificial profunda utilizada en este trabajo.

En la Figura 2.7a), se observa la velocidad para varios datos experimentales de la Tabla 2.1. En Figura 2.7b) se muestran los mismos datos de la velocidad experimental en el espacio (P, T). Por último, datos experimentales normalizados divididos en conjuntos de entrenamiento (azul) y de prueba (rojo) se muestran en la Figura 2.7c). La forma de dividir el conjunto de datos experimentales fue aleatoria, se hizo sólo una vez y se utilizaron para el entrenamiento de todas las redes neuronales. El rango de temperatura es $T = [276.1\text{K}, 282.6\text{K}]$ y presión de metano $P = [4.55\text{ MPa}, 10.7\text{ MPa}]$. Los valores experimentales de T y P se normalizan dividiendo todos los datos por el máximo correspondiente de T o P.

Nótese que los datos experimentales tomados de las referencias [1][2] no son adecuados para realizar análisis numéricos precisos, construir modelos que reproduzcan los datos o predecir rigurosamente los mismos; véase la Figura 2.6 y la Figura 2.7 por ejemplo, en el rango de temperatura $[276.1\text{K}, 276.6\text{ K}]$, se proporcionan muchos datos (14 de de 49 datos), mientras que en el rango de temperatura $[279\text{ K}, 280\text{ K}]$, no aparece ninguno. Adicionalmente hay rangos de presión, por ejemplo, $[5.70\text{ MPa}, 6.2\text{ MPa}]$, en los que no se informa de velocidades experimentales, mientras que hay muchos datos dados en otros rangos de presión, por mencionar uno; $[7.5\text{ Mpa}, 8.5\text{ Mpa}]$.

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO

No	T [K]	P [MPa]	Rate [mm^2/s]	No	T [K]	P [MPa]	velocidad [mm^2/s]
1	276.1	4.79	0.328	26	278.4	7.9	0.48592
2	276.1	4.83	0.371	27	278.8	6.7	0.12199
3	276.1	4.93	0.38	28	278.8	6.9	0.19019
4	276.1	5.14	0.586	29	278.8	7.5	0.37292
5	276.2	5.62	0.864	30	278.9	6.3	0.08491
6	276.2	6.23	1.409	31	280.4	6.85	0.03385
7	276.2	6.54	1.841	32	280.4	7.1	0.05983
8	276.2	6.85	1.996	33	280.6	7.21	0.07535
9	276.2	7.09	2.363	34	281.1	7.33	0.0445
10	276.2	7.43	2.747	35	281.3	8.04	0.09946
11	276.2	7.88	3.157	36	281.4	7.66	0.07096
12	276.2	8.25	3.396	37	281.4	8.12	0.09356
13	276.3	8.73	3.886	38	281.4	8.5	0.14728
14	276.6	4.55	0.03143	39	281.6	8.3	0.10498
15	277.4	9.57	1.9065	40	281.6	8.65	0.14215
16	277.8	9.12	1.61606	41	281.6	8.8	0.14571
17	277.9	8.1	0.6587	42	281.6	8.95	0.23662
18	277.9	8.5	0.81643	43	281.6	9.1	0.25738
19	277.9	10.3	1.8975	44	281.8	10.35	0.38424
20	277.9	10.7	1.86085	45	281.9	9.5	0.26543
21	278.1	5.15	0.02794	46	282.1	8.98	0.16202
22	278.1	6.7	0.28314	47	282.4	8.31	0.06448
23	278.1	7.4	0.38963	48	282.5	8.45	0.07815
24	278.1	7.55	0.35412	49	282.6	8.73	0.09026
25	278.1	8.9	0.77055				

Tabla 1.1: Datos experimentales de la velocidad de crecimiento de los hidratos de metano en función de la presión y la temperatura de las referencias [1][2].

El algoritmo de entrenamiento es de descenso de gradiente con impulso y la función de activación es sigmoide. Aunque existen algunas reglas básicas para elegir el mejor modelo de DNN para resolver un problema particular, ver por ejemplo [22–25]; estas reglas pueden no funcionar debido a muchos factores. Por ejemplo, el mejor número de capas ocultas depende de forma compleja del número de neuronas de entrada y salida, el número de casos de entrenamiento, la cantidad de ruido en los objetivos, la complejidad de la función objetivo, de la clasificación y de los patrones a aprender, del tipo de función de activación de las unidades ocultas, del algoritmo de entrenamiento, entre otros.

Se dividieron aleatoriamente los datos experimentales de la Tabla 2.1 en dos conjuntos a saber, 38 datos de la forma (velocidad,T,P) para el entrenamiento y el 22,45 %, 11 datos de la forma (velocidad,T,P) para la prueba. Estos conjuntos se mantienen iguales para el entrenamiento de todas las redes neuronales a lo largo del análisis que se presenta en este trabajo (véase la Figura 2.7c)). Los parámetros de la DNN también se asignan aleatoriamente, e incluyen la velocidad de aprendizaje y las épocas de entrenamiento. La DNN correspondiente se ejecuta para todo el conjunto de datos




Figura 1.6: Velocidad experimental de formación de hidratos de metano para diferentes presiones a temperatura constante [1][2].

de entrenamiento (T,P), y se producen las velocidades normalizadas. A continuación, se calcula la raíz media cuadrática (RMC) como medida de error utilizando tanto la velocidad de formación de HM producida de la DNN y los valores experimentales ese dato en particular (etiquetado por la velocidad de aprendizaje y el número de épocas) de la DNN. Un número pragmático de redes neuronales se define sobre el rendimiento del hardware disponible y definiendo una elección del número de épocas y velocidad de aprendizaje; en este caso, este número es de 417. Se entrenan y se prueban estas 417 DNNs. El mejor modelo DNN basado en el rendimiento (RMC mínimo) sobre los datos de prueba DNN_{best} se utiliza en este trabajo para producir nuevos datos de el conjunto de datos experimentales que aparecen en la Tabla 2.1 y en la referencia [1][2][3].

La Figura 2.8, muestra el RMC obtenido para cada uno de los modelos DNN propuestos. El punto rojo es el RMC mínimo que corresponde al modelo DNN etiquetado por el número 300 llamado DNN_{best} que fue elegido para generar el nuevo conjunto de datos utilizado para obtener la ecuación cinética empírica de crecimiento del HM mediante gplearn. En general, el RMC esta acotada entre 0.166 y 0.1; sin embargo, hay casos con RMC grandes, véase la DNN etiquetada con el número 49 en la Figura 2.8 ,con un RMC de alrededor de 0.375. La DNN elegida, DNN_{best} , tiene un coste de entrenamiento de 0.27996054 con 21460 épocas, una velocidad de aprendizaje de 0.02027055, un RMC calculado a partir del conjunto de datos de prueba de 0.074356, y corresponde al punto rojo de la Figura 2.8 es decir, el mas bajo del conjunto de redes entrenadas [3]. Se llama a esta red DNN_{best} .

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO




Figura 1.7: Cinética experimental de formación de hidratos de metano. a) velocidad en función del índice de datos experimentales de la Tabla 1. b) velocidad en función de T y P . c) Datos experimentales normalizados o reescalados divididos en conjuntos de entrenamiento (azul) y de prueba (rojo). [1][2][3]

Los datos generados por el DNN_{best} pueden verse como la superficie de la Figura 2.9a), donde los puntos representan los datos experimentales. Algunos datos (velocidad, T , P) que no están incluidos en las velocidades experimentales originales reportadas en la referencia [1][2] son producidos por DNN_{best} . En la Figura 2.9b), se muestran los datos generados por DNN_{best} comparados con los datos experimentales completos para las diferentes (49) etiquetas de datos experimentales. La proximidad de los valores de velocidad generados por el DNN_{best} a los datos experimentales se muestra en la Figura 2.9 7c). Por último, en la Figura 2.9d) se comparan los datos generados por el DNN_{best} con los datos experimentales en el conjunto de datos de prueba para las etiquetas de datos (11). Por lo tanto, se puede concluir que el modelo DNN_{best} se ajusta bien a los experimentos reportados en la literatura y puede utilizarse para imputar datos para la cinética de crecimiento del HM.

1.3. Ecuación empírica para la cinética de la formación de hidratos de metano.

Para encontrar una ecuación empírica para la cinética de formación de hidratos de metano se utilizó un algoritmo evolutivo, una herramienta de aprendizaje automático, llamado programación genética. La programación genética es una herramienta que parte de una población de relaciones de funciones (normalmente al azar) y aplica operaciones análogas a los procesos genéticos naturales. Es esencialmente una técnica de búsqueda




Figura 1.8: RMC para las diferentes DNNs utilizadas en este trabajo. El punto rojo corresponde a DNN_{best} ya que su RMC es el mínimo [3].

heurística, que busca un programa óptimo o al menos adecuado entre el espacio de todos los programas. Esta sección procede a utilizar el conjunto de datos (velocidad,T,P) obtenido mediante la red DNN_{best} para programar algoritmos genéticos para diferentes configuraciones y parámetros; la opción que mejor se ajusta a los experimentos se presenta en este trabajo como una nueva ecuación cinética empírica de crecimiento de los hidratos de metano. Se realizaron 2000 experimentos de programación genética sobre el conjunto de datos (velocidad,T,P) proporcionados por el DNN_{best} . [3].

De los 2000 experimentos genéticos, se eligió la ecuación con el menor RMC. El experimento genético elegido puede verse en la Figura 2.10 en rojo, tiene una población de 200000, generaciones de 200, criterio de parada de 0.005000, un cruce de 0.094433, mutación de subárbol de 0.479773, mutación de elevación de 0.364233, mutación de punto de 0.024886 y un coeficiente de parsimonia de 0.00289871. La ecuación tiene el RMC (mínimo) de 0.699 calculado utilizando la ecuación empírica dada en este documento y los datos experimentales de la Tabla 2.1. Por lo tanto esta ecuación empírica proporcionada por nuestro algoritmo es la siguiente;

$$\ln velocidad = \sqrt{-0.712T\sqrt{T} + 11.987T + P} - \sqrt{T/P}$$

En esta ecuación, T se expresa en grados Kelvin , P en MPa y la velocidad en mm^2/s . Las Figuras 2.9 muestran las predicciones de la ecuación empírica y los datos experimentales (velocidad,T,P) que aparecen en la Tabla 2.1. La Figura 2.9a) mues-

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO




Figura 1.9: Predicciones de la red neuronal profunda DNN_{best} y datos experimentales de la Tabla 1. Superficie predicha por DNN_{best} y puntos experimentales en a), valores de velocidad predichos por DNN_{best} y datos experimentales en b), predicción de velocidad mediante DNN_{best} frente a velocidad experimental; una medida del rendimiento de DNN_{best} en c), y predicciones de DNN_{best} comparadas con datos experimentales solo para el conjunto de pruebas en d). [3]

tra la solución de la ecuación cinética de crecimiento del hidrato de metano como la velocidad = función(T,P) y los datos experimentales como puntos en el espacio (velocidad,T,P); la Figura 2.9b) muestra la predicción de la ecuación empírica y el valor de la velocidad experimental para cada experimento de la Tabla 2.1. La ecuación empírica propuesta en este trabajo produce una velocidad de valor real en el rango de temperatura [270K, 284K] y rango de presión [0, 12M pa]. Aunque en la Figura 2.12c) vemos que la ecuación empírica no se ajusta muy bien a los datos experimentales; hace un trabajo bastante aceptable, teniendo en cuenta que éste es el primer intento reportado en la literatura de proponer una ecuación como modelo matemático para la cinética empírica de crecimiento de los hidratos de metano[3].




Figura 1.10: Programación genética; generaciones necesarias para diferentes poblaciones en los experimentos. El punto rojo corresponde al caso que produce la ecuación empírica reportada en este trabajo[3].




Figura 1.11: Velocidad dada por: los datos experimentales de la Tabla 1, la ecuación empírica y DNN_{best} , para cualquier índice experimental como el de la Tabla 2.1 [3].

1.4. Discusión y conclusiones preliminares

Para mejorar la comprensión de la cinética de formación de los hidratos de metano, normalmente se deben obtener más y mejores datos experimentales (velocidad, P, T).

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO




Figura 1.12: Predicciones de ecuaciones empíricas y datos experimentales de la cinética de formación de hidratos de metano. Superficie predicha por la ecuación empírica y puntos experimentales en a), predicciones de la ecuación empírica e índice de datos experimentales como se indica en la Tabla 1 en b), y rendimiento de la ecuación empírica en c) [3].

Desgraciadamente, no hay suficientes datos en el rango de presión y temperatura estudiados aquí; los experimentos actuales proporcionan un conjunto de datos pequeño y escaso.

Este trabajo pretende introducir un método sistemático de IA para tratar los casos en los que sólo se dispone de de datos pequeños y dispersos, para proponer ecuaciones empíricas con precisión aceptable. Utilizamos aquí el conjunto completo de datos experimentales (velocidad, T, P) en la Tabla 2.1 [1][2] con buenos resultados. La Figura 2.12c) muestra la precisión de las predicciones de la ecuación empírica con respecto a los valores experimentales ordenados como en la Tabla 2.1. Es fácil ver que la mayoría de los valores experimentales se sitúan bajo la curva de la ecuación empírica [3].

Por lo tanto, la ecuación empírica propuesta aquí sobreestima sistemáticamente el valor experimental para un conjunto dado de valores (T, P). A partir de la Figura 2.11, se puede observar que la mejor aproximación numérica a los datos experimentales viene dada por el DNN_{best} , seguido de la ecuación empírica que sobreestima sistemáticamente los datos experimentales. Sin embargo la ecuación empírica propuesta en este trabajo resume con facilidad mucha información y es más adecuada para aplicaciones como el estudio de los mecanismos moleculares de este fenómeno. También se observa que el modelo generado por la red DNN_{best} predice mejores valores experimentales que la ecuación empírica.

En las Figuras 2.14 se muestra el comportamiento de la velocidad de crecimiento

del hidrato de metano en el rango de los experimentos realizados: a saber, $T = [276,1\text{K}, 282,6\text{K}]$ y $P = [4,55\text{MPa}, 10,7\text{MPa}]$. Se consideró la velocidad en función de temperatura, para una presión constante a), y en función de la presión, para temperatura constante b) obtenida por el modelo DNN_{best} introducido en este trabajo. Del mismo modo, se introduce en las Figuras c) la velocidad como función de la temperatura a presión constante, y d) velocidad en función de la presión, para temperatura constante, obtenidas por la ecuación empírica propuesta en este trabajo. Éstas pueden compararse directamente con las Figuras 2.11 y 112.14 de J. Foroozesh et al. [20] obtenidas mediante un modelo de RNA y de sistema de inferencia difusa de neuronas adaptativas (ANFIS)[3].

Para temperaturas cercanas a 276K y altas presiones (cerca de 12Mpa), se predice que todas las velocidades se acercan a un límite constante [3], totalmente diferente de lo conjeturado anteriormente por J. Foroozesh et al. [20]. Para demostrar que este límite existe en el enfoque DNN_{best} se obtiene realizando experimentos computacionales en el rango [270K, 276K] donde no se dispone de datos experimentales, ver Figura 2.13. En esta Figura, de 270 K a 272K, se predice que la velocidad es aproximadamente constante e igual a $3,9 \text{ mm}^2/\text{s}$. Sin embargo, de 272K a 276K, se produce un fuerte descenso de la velocidad para presiones cercanas a 4,55 MPa; a medida que la presión aumenta hacia 10,5Mpa, la velocidad prevista es menos sensible a la temperatura.




Figura 1.13: Predicciones del límite de la velocidad constante por DNN_{best} [3]

La ecuación empírica, generada por programación genética, introducida en este trabajo, no predice una velocidad constante, como puede verse en la Figura 2.14c) y la Figura 2.14d). La velocidad en función de la presión, a temperatura constante, calculada mediante el modelo modelo DNN se muestra en la Figura 2.14b), para los mismos valores de temperatura que Figura 2.14 en [20]. Estos autores informan sobre un rango

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO

más amplio de datos de presión que nosotros, de 10,7Mpa a 12Mpa; sin embargo, no aparece ningún otro fenómeno físico que los fenómenos reportados en este trabajo. De 4Mpa a 10,7Mpa, la tendencia de nuestros datos es la misma que la de los datos de la Figura 2.14 en 2.14; sin embargo, la curvatura es diferente. Parece que el DNN_{best} predice un límite para la velocidad de crecimiento en torno a $3,5 \text{ mm}^2/\text{s}$ para temperaturas de 276,1K y altas presiones. Para temperaturas más altas (cerca de 282,6K), no hay límite en la velocidad de crecimiento. La ecuación empírica produce la Figura 2.14d) y, al igual que la Figura 2 de J. Foroozesh et al [20].




Figura 1.14: A partir del modelo DNN: a) velocidad en función de la temperatura a presión constante y b) velocidad en función de la presión a temperatura constante. A partir de la ecuación empírica: c) velocidad en función de la temperatura a presión constante y d) velocidad en función de la presión a temperatura constante [3].

Por último, se analiza las Figuras 2.15. Para el DNN_{best} , el cambio de la velocidad de crecimiento es significativo en el intervalo [276K, 279K], aproximadamente el mismo intervalo reportado por J. Foroozesh et al. [20]. Sin embargo, el modelo DNN_{best} predice velocidades mayores para presiones más bajas a la misma temperatura [20]. La ecuación empírica reportada en este trabajo predice cambios significativos en la velocidad de crecimiento en el mismo intervalo [276K, 279K] que los casos DNN_{best} [3] y de referencia [20]; sin embargo, estos cambios ocurren a presiones más altas y producen valores de velocidad más altos. Existen claras diferencias entre las Figuras 2.15a) y 2.15b); mencionemos dos de ellas: a) los cambios de velocidad a diferentes presiones para la misma temperatura (cerca de 276K) y b) hay un valor de velocidad de crecimiento diferente más alta para la ecuación empírica.




Figura 1.15: velocidad de crecimiento de los hidratos en función de la temperatura en K y la presión en MPa dada por: a) el modelo DNN y b) la ecuación empírica introducida en este trabajo. La línea roja muestra el estado de equilibrio dado por la referencia [4][3] .

En resumen, se propone una ecuación empírica como modelo cuantitativo para el crecimiento del hidrato de metano en una cinética de superficie de burbuja. Esta ecuación se obtiene mediante programación genética a partir de los datos imputados por DNN_{best} . Aunque DNN_{best} se ajusta mejor a los datos experimentales en Tabla 2.1 que la ecuación empírica (se produce una sobreestimación consistente), se exponen ambos modelos. Además, si se necesita un modelo de predicción preciso, DNN supera, como se muestra aquí, al modelo gplearn. Mientras que, cuando un modelo para verificar un mecanismo de reacción, el control y la optimización de la producción de metano a partir de HM , no se puede usar DNN, una ecuación como la reportada en este trabajo es adecuada para la tarea. Este trabajo muestra el primer intento de introducir una evaluación cuantitativa o ecuación empírica como modelo matemático para esta cinética compleja.

Con esto, concluye el actual capítulo dedicado al estudio de la formación de hidratos de metano, donde hemos explorado desde la velocidad de formación hasta la imputación de datos y la generación de ecuaciones descriptivas utilizando algoritmos genéticos. El análisis ha demostrado cómo las técnicas avanzadas de inteligencia artificial pueden proporcionar una comprensión significativa de fenómenos complejos en la química del

1. FENÓMENO DINÁMICO: CINÉTICA DE FORMACIÓN DE HIDRATOS DE METANO

metano.

En el próximo capítulo se abordará el siguiente fenómeno dinámico: el estudio de las propiedades electromagnéticas de las antenas fractales de Peano. Se aprovecharon las herramientas de aprendizaje automático para explorar estas estructuras geométricas únicas, ampliando el entendimiento de su comportamiento en un contexto electromagnético

Fenómeno dinámico caso: Antenas fractales de Peano

En este capítulo, se investigó el comportamiento de antenas fractales, tanto de estructura determinística como pseudoaleatoria. Entre las antenas de estructura determinística, se prestó especial atención a las antenas de Peano, debido a su peculiar geometría. Se realizaron descubrimientos significativos en relación con las propiedades de estas antenas, destacando la obtención de comportamientos únicos en función de la naturaleza de su estructura. Esto fue posible gracias a un enfoque intensivo en la recopilación y análisis de datos.

La contribución más destacada de este capítulo radica en la presentación de ecuaciones que describen estos comportamientos. Para su derivación, se emplearon herramientas de Inteligencia Artificial, reforzando una vez más la eficacia de estas técnicas en el estudio de fenómenos complejos.

Una antena es un dispositivo diseñado para transmitir y recibir ondas electromagnéticas, como ondas de radio o microondas. Convierte las señales eléctricas en ondas electromagnéticas y viceversa, lo que permite la comunicación inalámbrica entre dispositivos electrónicos. Las antenas son componentes esenciales en una amplia variedad de sistemas de comunicación y tienen varias características principales y aplicaciones. Entre sus características principales se tienen:

- Directividad: La directividad de una antena es la capacidad de la antena para enfocar la energía en una dirección específica en lugar de irradiarla en todas las direcciones. Esto es útil para aumentar la eficiencia de la transmisión y reducir la interferencia con otros sistemas de comunicación.
- Polarización: La polarización de una antena se refiere a la orientación y el comportamiento en el tiempo del vector del campo eléctrico de las ondas electromagnéticas transmitidas o recibidas por la antena. La polarización puede ser lineal (vertical u horizontal) o circular y es importante para garantizar la compatibilidad entre las antenas del transmisor y el receptor.

2. FENÓMENO DINÁMICO CASO: ANTENAS FRACTALES DE PEANO

- Impedancia: La impedancia es una medida de la resistencia que ofrece una antena al flujo de corriente eléctrica.
- Ancho de banda: El ancho de banda de una antena es el rango de frecuencias en el que la antena puede operar de manera eficiente. El ancho de banda es una característica importante para determinar la cantidad de datos que se pueden transmitir a través de una antena en un período de tiempo determinado.

Las nuevas tecnologías de comunicación requieren una transmisión eficiente de la información a través de antenas multibanda y compactas, las nuevas aplicaciones ponen a prueba diseños y geometrías de antenas diferentes y poco usadas. Por otra parte, las antenas compactas son fundamentales para algunas redes inalámbricas y aplicaciones de comunicación personal.

El estudio de las antenas fractales comenzó en la década de 1980 debido a la accesibilidad de sistemas computacionales y herramientas para su modelado y simulación. Las antenas fractales son aquellas que incorporan estructuras fractales en su diseño. Los fractales son formas geométricas que se repiten en diferentes escalas y tienen propiedades de auto-similitud. La geometría fractal ayuda a diseñar pequeñas antenas multibanda. Algunos fractales presentan copias de su estructura completa a pequeñas escalas; este atributo se denomina autosimilaridad, una característica que beneficia el diseño de antenas multibanda[26].

El VSWR (por las siglas en inglés de Voltage Standing Wave Ratio que significa Voltaje de Onda Estacionaria Reflejada) de una antena es un parámetro importante porque proporciona información sobre la capacidad de la antena para transferir energía de radiofrecuencia desde un transmisor a una carga. Cuando una señal de radiofrecuencia se transmite desde un transmisor a través de una antena, una parte de la señal se refleja de vuelta en la antena debido a una variedad de factores, como la impedancia de la antena o la longitud de onda de la señal. Esta señal reflejada puede causar una interferencia y provocar una pérdida de señal. El VSWR es una medida de la cantidad de señal reflejada en comparación con la señal transmitida,

Un VSWR es la relación entre las magnitudes del voltaje máximo y mínimo de la línea, un valor alto indica una mala adaptación de impedancia entre la antena y el transmisor o la carga, lo que significa que hay más señal reflejada de la que se transmite, lo que resulta en una menor eficiencia de la transmisión y una pérdida de señal. Por otro lado, un VSWR bajo indica una mejor adaptación de impedancia entre la antena y el transmisor o la carga, lo que significa que se está transmitiendo más señal y menos señal está siendo reflejada, lo que resulta en una mejor eficiencia de la transmisión y una menor pérdida de señal.

En resumen, el VSWR es un parámetro importante porque indica cuánta energía de la señal de radiofrecuencia es transferida de manera efectiva desde la antena trans-

misora a la antena receptora, lo que es crítico para una transmisión exitosa de señal de radiofrecuencia.

Si el VSWR es igual a 2, la potencia reflejada es el 11.11 % de gamma (Γ^2) (donde gamma es el coeficiente de reflexión) en el punto de alimentación de la antena [27]. Las especificaciones mas comunes para una antena son una return loss (RL) mayor a 10 dB o un $VSWR \leq 2$ y es por ello que sera un objetivo de simulación en las antenas estudiadas en este trabajo . Para antenas de teléfono móviles es común un VSWR menor de 3 o un $RT > 6\text{dB}$ [28] [29] [30] .

Las propiedades de radiación de las antenas clásicas son bien conocidas; se calculan fácilmente con programas informáticos comerciales como COMSOL Multiphysics, Ansys HFSS, FEKO, HFWorks, Sonnet Software WIPL-D Pro, Empire XPU, Remcom Xfdtd, AWR Microwave Office y CST MICROWAVE STUDIO. La capacidad multi-banda y las estructuras compactas son necesarias para las aplicaciones actuales más exigentes; un mismo dispositivo de comunicación exige la conexión de múltiples servicios. En este trabajo se estudian las propiedades de antenas en la banda de frecuencias UHF (300MHz-3000MHz) debido a aplicaciones científicas y comerciales potenciales; sin embargo, nuestro modelo puede tratar cualquier otra banda de frecuencias del espectro electromagnético. electromagnética.

Las aplicaciones UHF incluyen las bandas de radio industriales, científicas y médicas (ISM) (433.92 MHz, 915 MHz, 2.45 GHz), sistemas de localización GPS (1575.42 MHz, 1227.60MHz, 1381.05MHz, 1176.45MHz), sistemas de navegación por satélite basados en el espacio como Galileo (1575.42 MHz, 1191.795 MHz, 1176.45 MHz, 1207.14 MHz, 1278.75MHz) y GLONASS (1602.0MHZ), enlace ascendente/descendente de banda L para la constelación de satélites Iridium de órbita baja (1618-1626.5 MHz), comunicaciones celulares (870-960 MHz), WiFi 802.11b, 802.11g y 802.11n (2400 MHz), e identificación por radiofrecuencia o RFID (868 - 956 MHz), (2400-2483.5 MHz) o utilizados como investigación radioastronómica (1660.5-1668.4 MHz), entre otros.

2.1. Antecedentes

Muchas personas han contribuido al estudio de la geometría fractal: Mandelbrot, W. Sierpinski, D. Hilbert, H. Minkowski, N. F. H. von Koch y G. Peano, entre otros. En la literatura se han utilizado varias curvas fractales como geometrías para antenas [30], por ejemplo, antenas de Minkowski, Koch, Moore, Hilbert, Peano, Sierpinski y Dragon[31–34] .

La curva propuesta por Hilbert en 1817 es una de las curvas más conocidas que llenan el espacio, se autoevitan y son autosimilares FASS por sus siglas en ingles space-Filling, **S**elf-**A**voiding, **S**imple (single-stroke) and **S**elf-similar es decir la curva rellena

2. FENÓMENO DINÁMICO CASO: ANTENAS FRACTALES DE PEANO

un de espacio, es auto-evitable, simple (un solo trazo) y auto-similar.

Las antenas FASS proporcionan estructuras compactas y existen diferentes geometrías de interés para su estudio. Hasta ahora se han encontrado muchas características para antenas Hilbert [32, 35–42]. La curva de Peano ¹ ha inspirado a los ingenieros de antenas a diseñar tanto antenas pequeñas, elementos de alta directividad, conjuntos y superficies selectivas de frecuencia [43–52]. Otros estudios en esta línea de pensamiento se han publicado en la literatura [45, 53–57].

La investigación de J. Zhu, A. Hoorfar y N. Engheta [32]4 sobre las antenas Peano ha servido de inspiración para el modelo propuesto en esta tesis. En este trabajo, se analizaron las propiedades de radiación de varias antenas Peano. Se estudian las iteraciones 1,2,3 y 4 del fractal Peano obteniendo sus frecuencias de resonancia. Además, se analizan los diferentes anchos de banda alrededor de la frecuencia central donde el $VSWR \leq 2$ por cada iteración. Las propiedades de radiación de la antena Peano se escanean a lo largo de con la banda UHF. Se considera que el enfoque abordado en este trabajo contribuye al estudio de las propiedades de las antenas Peano, un caso particular de las antenas FASS. Además del método MoM estándar para resolver las ecuaciones de Maxwell, introducimos novedosas herramientas de Inteligencia Artificial como la programación genética mediante gplearn para la obtención de ecuaciones que describan las propiedades encontradas.

Las herramientas computacionales utilizadas aquí han permitido generar ecuaciones que relacionan el tamaño de la antena L con F , siendo F la frecuencia de resonancia y también L con la frecuencia central tal que $VSWR \leq 2$. Además, se obtienen los anchos de banda en torno a las frecuencias centrales tales que $VSWR \leq 2$. Así, se proporciona una comprensión más profunda de las antenas Peano que los resultados ya reportados en la literatura. Se elige el aire como sustrato para acelerar los cálculos de MoM; este sustrato puede cambiarse fácilmente.

Se proporcionan ecuaciones para dos condiciones de un diseño de antena Peano adecuado; a) las frecuencias de resonancia y b) las frecuencias en las que la $VSWR \leq 2$, ambas en función del tamaño lateral de la antena L . Hasta ahora éste es el primer trabajo donde se reportan tales ecuaciones (o cualquier otro modelo matemático) sobre este tema. Aquí se presenta una aplicación en Python 3.7 que está disponible en GitHub para acceder a la totalidad de los resultados y ejemplos aquí reportados, y pro-

¹ La curva de Peano es una curva fractal y espacio-relleno, descubierta por el matemático italiano Giuseppe Peano en 1890. Se trata de una curva continua que pasa por cada punto en un cuadrado unitario sin cruzarse a sí misma. Aunque parece una línea simple, la curva de Peano posee propiedades matemáticas interesantes y complejas, por ejemplo: a pesar de ser continua, la curva de Peano no es diferenciable en ningún punto. La dimensión fractal de la curva de Peano es mayor que su dimensión topológica (la dimensión de una línea, que es 1). La dimensión fractal de la curva de Peano es $\log(3)/\log(2) \approx 1.585$, lo que indica que es más compleja que una línea unidimensional pero menos compleja que una superficie bidimensional.

ducir otros adicionales que puedan ser útiles para la comunidad interesada en el tema [27]. Esta aplicación funciona proporcionando : a) las frecuencias de resonancia y b) las frecuencias tales que $VSWR \leq 2$), en la banda UHF, con los puntos de alimentación examinados aquí y tres anchos de microstrip y c) para producir la geometría de antenas Peano que abarcan un tamaño lateral L entre 0.01m y 0.1m y poder ser simuladas en MATLAB.

2.2. Simulaciones numéricas.

Para abordar en primera instancia el análisis de antenas con estructura de curva de Peano se definirán los alcances de las simulaciones computacionales para el siguiente paso, que es simular sobre puntos específicos de la estructura de las antenas.

Se elige el metal para construir las antenas microstrip Peano y el aire como sustrato para simplificar las simulaciones y enfocar el trabajo en las consecuencias en el diseño de la iteración de las reglas de producción de la antena fractal Peano, las posiciones de los puntos de alimentación, el área abarcada por la geometría, y la anchura de la antena Peano de microstrip con respecto a las frecuencias de resonancia y en donde el $VSWR \leq 2$. Las simulaciones se llevaron a cabo desde 290 MHz hasta 3100 MHz; este rango de frecuencias contiene la banda de frecuencia UHF y evita problemas numéricos en los límites de la misma. Además, se usó una resistencia de 50Ω en la línea de alimentación a lo largo de este trabajo. En este caso, se aplica el método de los momentos (MoM) para resolver las ecuaciones de Maxwell en la antena metálica microstrip Peano con aire como sustrato utilizando el toolkit de antenas de [58]. La longitud de la antena es determinada por la ecuación $S = (3^n + 1)L$ donde: n es el número de iteración de la curva y L es el tamaño lateral de la antena.

Se crea la malla de la antena Peano con segmentos cuadrados $d \times d$, donde d se fija en 0.25 mm, 0.5 mm y 1 mm. Las antenas Peano son simétricas bajo un giro en sentido contrario a las agujas del reloj de 180 grados. Hay que tener en cuenta que esta simetría de la antena Peano nos permite extender nuestros resultados a las antenas con puntos de alimentación con posiciones en $9/16$ (igual a $7/16$) veces S , $11/16$ (igual a $5/16$) veces S , y $7/8$ (igual a $1/8$) veces S , dichos puntos pueden verse en la Figura 3.1. Aquí se pueden ver los puntos de alimentación para Peano 1, Peano 2 y Peano 3. Por la extensión del trabajo solo se explican los resultados obtenidos para la iteración 1, para las demás iteraciones, el lector puede obtener los datos en la aplicación que se presenta.

Las antenas Peano con puntos de alimentación en $1/8S$, $5/16S$, $7/16S$, $1/2S$, $9/16S$, $11/16S$, $7/8S$ son los únicos casos de puntos de alimentación estudiados en este trabajo. Además, utilizamos un tamaño lateral L que varía en el rango de (0m, 0.1m) y el número de iteración ($i=1,2,3$). El regresor simbólico [59] identifica las expresiones

2. FENÓMENO DINÁMICO CASO: ANTENAS FRACTALES DE PEANO

matemáticas subyacentes en los datos obtenidos de ambas simulaciones; las frecuencias de resonancia y las frecuencias tales que $VSWR \leq 2$.




Figura 2.1: Puntos de alimentación $1/2S$ (rojo), $5/16S$ (cyan), $7/16S$ (magenta) y $1/8S$ (verde). a) Antena Peano, $i = 1$ (Peano_1), b) Antena Peano $i=2$ (Peano_2), and c) Antena Peano, $i = 3$ (Peano_3). [5]

Los resultados de la simulación de la antena Peano, es decir, las simulaciones de resistencia, reactancia y VSWR, producen una base de datos guardada para su posterior análisis. El método aquí presentado construye una geometría de antena Peano utilizando un generador de geometría de sistema L que establece una anchura de antena d , un punto de alimentación, y un L para el área $L \times L$. A continuación, calculamos las características electromagnéticas de las antenas utilizando MoM en MATLAB. Este procedimiento se repite hasta generar una base de datos de 996 antenas simuladas.

Después de la obtención de los datos por medio de simulación computacional, se procesan y separan los datos que serán necesarios para la posterior aplicación de la regresión simbólica. En primer lugar se calculan los puntos de resonancia, calculando el punto mas próximo de cruce por cero del valor de frecuencia de la reactancia, esto se logra obteniendo las frecuencias, antes y después del cruce, el punto mas exacto se obtiene creando una aproximación lineal con esos puntos y calculando la raíz del polinomio generado. Los valores de VSWR son separados y todos aquellos menores o iguales a 2 se guardan en una base de datos para usarse posteriormente. Se ejecuta un lote de 1000 algoritmos genéticos sobre estos datos con parámetros de configuración elegidos al azar, número de generaciones y población inicial del algoritmo. De ello se obtienen funciones que relacionan la frecuencia de resonancia y las ecuaciones de las frecuencias de tal manera que $VSWR \leq 2$ como funciones del tamaño de la antena L que define la superficie $L \times L$. En el diagrama 3.2 puede observarse esquemáticamente el método empleado para generar los resultados.

2.3. Resultados.

Esta sección presenta los patrones de las frecuencias de resonancia y las frecuencias tales que $VSWR \leq 2$. En primer lugar, introducimos nuevas ecuaciones que caracterizan la frecuencia de resonancia y las frecuencias centrales tales que $VSWR \leq 2$ como reglas principales para producir pequeñas antenas Peano (que cubren un área inferior a $0.01m^2$). Comenzamos introduciendo el análisis de la frecuencia de resonancia para $i=1,2,3$.

A continuación, se estudian las frecuencias en las que $VSWR \leq 2$ para $i=1,2,3$. Los resultados más esenciales de este trabajo son las ecuaciones obtenidas utilizando GPlearn como regresor simbólico para las frecuencias de resonancia y las frecuencias en las que $VSWR \leq 2$ como funciones de L ; ambas ecuaciones son de la forma $L = aF^{-1} + b$. Aquí a y b son parámetros que se obtienen mediante el ajuste por mínimos cuadrados. F es la frecuencia de resonancia para el primer caso y la frecuencia central tal que la $VSWR \leq 2$ en el segundo caso. También proporcionamos los coeficientes polinómicos de segundo grado que relacionan la llamada frecuencia central (el valor medio) tal que $VSWR \leq 2$ con el ancho de banda alrededor de ésta como porcentaje de la frecuencia central. F está siempre en MHz y L en metros.

Nuestras simulaciones producen muchos resultados numéricos que ilustramos en este trabajo. Dado que estos resultados de simulación más otros numéricos adicionales se pueden obtener a través de la aplicación Peano'antennas [27], se considera que los ejemplos presentados aquí y esta aplicación disponible en GitHub representan bien nuestro enfoque.

Se obtiene los datos de impedancia de las antenas Peano, barriendo la frecuencia desde 290 MHz, con un incremento de frecuencia de 0,25 MHz (para $i=1,2$) y 1MHz (para $i=3$), hasta 3100MHz. Se obtienen 11241 datos de impedancia (para $i=1,2$) y 2811 datos de impedancia (para $i=3$). A continuación, se buscan los cruces por cero de la reactancia; así, calculamos las frecuencias de resonancia. Para las antenas Peano iteración 3, realizamos los cálculos con un paso de frecuencia de 1MHz para mantener un equilibrio razonable entre el tiempo de cálculo utilizado para las simulaciones y la complejidad de la antena. Se estudiaron las ecuaciones de frecuencia de resonancia para las antenas Peano generadas por la iteración de la regla de producción $i=1,2,3$. Los pasos del método utilizado están descritos en el diagrama de la Figura 3.2.

2.4. Peano 1

A continuación se presentan los resultados del caso que se llama Ejemplo 1. La Figura 3.3 muestra las frecuencias de resonancia calculadas en la banda UHF para las antenas Peano'1, $L < 0.10m$ con punto de alimentación situado a $0,125$ ($1/8$) veces la

2. FENÓMENO DINÁMICO CASO: ANTENAS FRACTALES DE PEANO




Figura 2.2: Diagrama de flujo del método utilizado en este trabajo. El primer bloque (verde) es el módulo de caracterización de antenas Peano. El segundo bloque (marrón) es el módulo de frecuencia de resonancia. El tercer bloque (blanco) es el módulo de frecuencias tales que la $VSWR \leq 2$, y el cuarto bloque (naranja) es el módulo de solución.

longitud S , y $d=0.25$ mm, $d=0.5$ mm, $d=1.00$ mm. Recordemos que las frecuencias de resonancia dependen de la posición del punto de alimentación, de la geometría y de la anchura de la antena microstrip. Los patrones, fácilmente descritos mediante ecuaciones, aparecen en la Figura 3.4. Las frecuencias de resonancia se indican para la banda UHF (para ser más precisos, $300\text{MHz} < F < 3000\text{MHz}$) para diferentes valores de L ($L < 0.1\text{m}$), y el punto de alimentación situado a 0.125 veces S . Se aplicó gplearn programación dinámica, para obtener las posibles funciones adecuadas para describir las curvas mostradas en la Figura 3.3.

Las mejores funciones posibles que se ajustan a estas curvas son $L = aF^{-1} + b$. Los parámetros a y b para todas las curvas mostradas en la Figura 3.3 se indican en la Tabla A.1. En esta Tabla, además de los parámetros correspondientes, a y b para cada




Figura 2.3: Frecuencia de resonancia simulada para la antena Peano, $i=1$ (Peano_1) con punto de alimentación situado a 0.125 (1/8) veces la longitud S , $L < 0.10m$, y anchura de antena de 0.25 mm, 0.5mm, y 1.0mm [5]

curva, el rango de validez $\text{Min}(F) < F < \text{Max}(F)$ para el ajuste de cada curva y la raíz cuadrada (RMC). Tenga en cuenta que para cada ancho de antena, hay diez ecuaciones y curvas de resonancia; cada curva está etiquetada con un número que se muestra en la Tabla A.1 y la Figura 3.3.

El ejemplo 2 muestra cómo la antena Peano 1 produce tres ecuaciones diferentes del tipo $L = aF^{-1} + b$, cada una con un rango de frecuencia de validez y RMC, para una anchura de antena determinada (0.25 mm, 0.5 mm y 1.0 mm). Los parámetros a y b se obtienen de la Tabla A.1; esto se hace para el punto de alimentación 1/8 veces S , hay que recordar que L está dado en metros, d en mm y F siempre en MHz. A partir de la Tabla A.1, la curva de resonancia etiquetada como 0, para $d=0.25$ mm, obtenemos la siguiente ecuación, $L = 39.3092F^{-1} + 61.0359 \times 10^{-5}$, para la frecuencia de resonancia F y la distancia L , válida en el rango de frecuencias $390.3627\text{MHz} < F < 2668.6079\text{MHz}$, con una $\text{RMC} = 2292.47 \times 10^4$. Si se cambia a $d=0.5\text{mm}$, entonces la nueva ecuación es $L = 39.4893F^{-1} + 90.5418 \times 10^5$, válida para el rango de frecuencia de resonancia de $392.2852\text{MHz} < F < 2686.0016\text{MHz}$ con RMC igual a 2711.02×10^{-7} . Finalmente, si se cambia a $d=1\text{mm}$, la ecuación obtenida tiene la forma $L = 39.7111F^{-1} + 142,6563 \times 10^5$, para el rango de validez de la frecuencia de resonancia de $398,4707\text{MHz} < F < 2897.3903\text{MHz}$, con una $\text{RMC} = 3320,47 \times 10^{-7}$.

En la Tabla A.2 se muestran los parámetros de las curvas de frecuencia de resonancia $L = aF^{-1} + b$ para las antenas Peano 1 en tres anchos de antena d (0.25 mm, 0.5 mm y 1 mm), con el punto de alimentación situado a 0.3125 (o 5/16) veces la longitud S de la antena. Observe que existen ocho curvas de resonancia en lugar de las diez curvas de frecuencia de resonancia si el punto de alimentación se coloca a 0.125 veces S para la simulación de la antena Peano 1. La Tabla A.3 muestra los parámetros de las curvas




Figura 2.4: Frecuencia de resonancia F en función de la longitud L para antenas Peano'1 con punto de alimentación situado a 0,125 (1/8) de S para una anchura de antena de 0,25mm. [5].

de frecuencia de resonancia $L = aF^{-1} + b$ para las antenas Peano'1 con tres anchos de antena diferentes (0.25 mm). anchura de la antena (0.25 mm, 0.5 mm, 1 mm), y punto de alimentación situado a 0.4375 (o 7/16) veces la longitud de la antena S . En este caso, hay diez curvas de resonancia. Los parámetros de la antena Peano'1, punto de alimentación situado a 0.5 (o 1/2) veces la longitud S se muestran en la Tabla 6. Sólo son posibles dos curvas de resonancia para la anchura de la antena de 1 mm. Las tablas A.1, A.2, A.3, y A.4 proporcionan la información necesaria para diseñar, a través de sus frecuencias de resonancia, muchas antenas Peano 1, de forma similar.

A pesar de la relativa simplicidad de la antena Peano con iteración 1, se observan algunos patrones intrigantes en las curvas de frecuencia de resonancia para antenas con puntos de alimentación colocados en (1/8, 5/16, 7/16, 1/2, 9/16, 11/16, 7/8) veces la longitud S , y la d simulada: 0.25mm, 0.5mm, y 1mm. El número de curvas de resonancia y los valores de sus parámetros varían para antenas con el mismo punto de alimentación pero con diferentes anchos de antena microstrip Peano o al revés. Con respecto a estas curvas de resonancia, las antenas Peano 1 con puntos de alimentación situados a 1/8 veces S se describen en la Figura 3.3

Para iteraciones superiores de la regla de producción i , en particular, $i=2,3$, las propiedades de radiación, en particular la frecuencia de resonancia de las antenas Peano, pueden obtenerse utilizando la aplicación Peano'antennas disponible en la [27].

2.5 Ecuaciones para las frecuencias donde el VSWR ≤ 2 .

		Peano iteración 1 0.25 mm				
Punto de alimentación	curva	a	b	RMS	Min(F)	Max(F)
		[m MHz]	$[\times 10^{-5}m]$	$[\times 10^{-7}]$	[MHz]	[MHz]
1/8 S	0	39.3205	60.3841	2305.10	390.3750	2668.6250
1/8 S	1	74.3302	4.0267	411.62	734.5000	2950.2500
5/16 S	0	74.3252	3.0872	496.59	734.3750	2949.1250
5/16 S	1	Peano iteración 1 0.50 mm				
5/16 S	2	39.5027	89.7354	2631.12	392.3750	2686.2500
5/16 S	3	74.2484	17.3755	519.44	732.8750	2933.7500
5/16 S	4	74.2390	16.3716	451.96	732.6250	2932.1250
5/16 S	5	Peano iteración 1 1.00 mm				
5/16 S	6	39.7195	142.4375	3257.86	398.5000	2898.3750
5/16 S	7	74.1472	46.1878	542.02	737.6250	2796.0000
5/16 S	8	74.1412	43.8112	598.00	737.3750	2793.7500

Tabla 2.1: Peanno.1. Parámetros para las ecuaciones VSWR ≤ 2 , d igual a 0,25mm, 0,5mm y 1,0mm. El punto de alimentación se coloca a 0,125 (o 1/8) y 0,3125 (5/16) veces la longitud S .

2.5. Ecuaciones para las frecuencias donde el VSWR ≤ 2 .

Se calculan el llamado ancho de banda BW de las frecuencias en las que VSWR ≤ 2 , que es una condición necesaria para un rendimiento adecuado de la antena. En primer lugar, se obtiene el valor medio de este rango de frecuencias y se denomina la frecuencia central F . GPlearn muestra que F puede relacionarse con L mediante ecuaciones de la forma $L = aF^{-1} + b$, con los parámetros a y b de la Tabla 3.1 para antenas Peano 1 con el punto de alimentación situado a 0.125 (o 1/8) y 0.3125 (o 5/16) veces la longitud S .

El ancho de banda BW (o gama de frecuencias) se indica como porcentaje de la frecuencia central f mediante un ajuste polinómico de segundo grado, es decir, mediante un de segundo grado; es decir, mediante ecuaciones de la forma $BW = \alpha F^2 + \beta F + \gamma$, donde los parámetros α , β , y γ se toman de la Tabla 3.2 para Peano 1 y el punto de alimentación situado en 0.125 (o 1/8) y 0.3125 (o 5/16) veces la longitud S . La Figura 3.5 muestra los datos simulados para la frecuencia F y L agrupados en curvas, que corresponden a ecuaciones de la forma $L = aF^{-1} + b$ (obtenidas por gplearn), para el punto de alimentación situado a 0.125 (1/8) veces la longitud S y tres anchos de antena diferentes : 0.25 mm, 0.5 mm y 1.0 mm.

Se completa esta descripción de la VSWR de la antena Peano 1 calculando el ancho de banda BW alrededor de la frecuencia central donde VSWR ≤ 2 . En concreto, buscamos el límite superior e inferior de BW como porcentaje de la frecuencia central; los valores porcentuales se relacionan con la frecuencia central utilizando un ajuste polinómico de segundo grado $BW = \alpha F^2 + \beta F + \gamma$, aquí BW es dado en porcentaje de F .

En Tabla 3.1 se encuentran los coeficientes de las ecuaciones de ancho de banda

2. FENÓMENO DINÁMICO CASO: ANTENAS FRACTALES DE PEANO

		Peano iteración 1 0.25 mm					
Alimentación	curva	$\alpha[\times 10^{-8}]$	$\beta \times 10^{-5}$	γ	RMC	Min(F) [MHz]	Max(F) [MHz]
1/8 S	0	-5.5556	36.3870	0.8283	0.1138	390.38	2668.62
1/8 S	1	-4.9990	40.1808	1.3894	0.0602	734.50	2950.25
5/16 S	0	-5.2276	41.1223	1.6628	0.0511	734.38	2949.12
		Peano iteración 1 0.50 mm					
5/16 S	0	-6.3695	45.3588	0.9312	0.1160	392.38	2686.25
5/16 S	1	-4.8191	46.4522	1.5673	0.0473	732.88	2933.75
5/16 S	2	-5.8774	49.5699	1.8295	0.0499	732.62	2932.12
		Peano iteración 1 1.00 mm					
5/16 S	0	-7.1773	59.2836	1.0448	0.1279	398.50	2898.38
5/16 S	1	-7.0395	65.3624	1.7171	0.0612	737.62	2796.00
5/16 S	2	-9.0847	68.7123	1.9768	0.0673	737.38	2793.75

Tabla 2.2: Peano_1. Coeficientes polinómicos necesarios para calcular el ancho de banda en torno a la frecuencia central de forma que $VSWR \leq 2$. Para una anchura de antena de 0.25 mm, 0.5 mm y 1.0 mm, punto de alimentación situado a 0.125 (o 1/8) y 0.3125 (o 5/16) veces la longitud S .

resultantes, α , β , γ , calculadas para anchos de antena de 0.25mm, 0.5mm y 1mm. Además, estos coeficientes se dan para puntos de alimentación situados a 0.125 (1/8) y 0.3125 (5/16) veces la longitud S . Para una frecuencia central de 1000 MHz, se pueden simular las antenas Peano 1 adecuadas con $VSWR \leq 2$ y el correspondiente ancho de banda alrededor de la frecuencia central.

A partir de la Tabla 3.1, cualquiera de las tres antenas microstrip Peano 1 (0.25mm, 0.5mm, 1.0mm) y dos puntos de alimentación (1/8 y 5/16 veces S), ya que 1000 MHz es, en cada caso, un rango de frecuencias válido. Es fácil ver que obtenemos un diseño adecuado si el punto de alimentación se coloca en 1/8 veces S con una anchura de antena de 0.25mm. En estas condiciones, la ecuación para determinar el tamaño L de la antena es $L = 39.3205F^{-1} + 60,3841 \times 10^{-5}$; el valor de L para 1000 MHz a partir de esta ecuación es $3.9924 \times 10^{-2}m$ o 3.9924 cm con un RMC igual a 2305.10×10^{-7} .

La tabla 3.2 muestra los parámetros del polinomio que proporcionan los valores del ancho de banda alrededor de la frecuencia central de 1000MHz; así, se obtiene $BW = -5.5556 \times 10^{-8}F^2 + 36.3870 \times 10^{-5}F + 0.8283$, con un RMC de 0.1138 que para 1000MHz da un $BW = 1.1366\%$. En resumen, las características de la antena Peano 1 propuesta con una $VSWR \leq 2$ son: $L=3.9924cm$, $d=0.25mm$, alimentación de punto a 1/8 veces S , y $BW = 1.1366\%$.

Para iteraciones superiores de la regla de producción i , en particular, $i=2,3$, las propiedades de radiación, en particular, las frecuencias tales que $VSWR \leq 2$ de las antenas Peano, pueden obtenerse utilizando la aplicación Peano disponible en la [27]. Sin embargo para $i > 3$, la aplicación sólo proporciona la geometría de la antena Peano hasta el momento. Por ejemplo, la Figura 3.6 muestra las resonancias de frecuencia de la Peano de la iteración 3. Las ecuaciones que describen estas curvas están en la

aplicación Peano [27] ; los puntos azules en la Figura 3.6 son los datos obtenidos de las simulaciones computacionales.




Figura 2.5: Peano_1. Punto de alimentación situado a 0.125 (o 1/8) veces S , $VSWR \leq 2$, curvas para las siguientes anchuras de antena: a) 0.25mm, b) 0.5mm, y c) 1.0mm.




Figura 2.6: Curvas de frecuencia de resonancia de una antena de Peano iteración 3, con el punto de alimentación a $1/2S$ con un ancho de 0.5mm. Los puntos corresponden a los datos usados para ajustar las funciones,

2.6. Discusión y conclusiones preliminares

Las antenas fractales ofrecen un rendimiento mejorado en comparación con las antenas convencionales. Debido a su estructura fractal pueden recibir y transmitir señales en múltiples frecuencias, lo que las hace más versátiles y eficientes. Son compactas y pueden ser diseñadas para adaptarse a una amplia gama de tamaños y formas. Esto es especialmente importante en aplicaciones donde el espacio es limitado, como en dispositivos electrónicos portátiles. Se pueden utilizar en una amplia gama de aplicaciones, como la comunicación inalámbrica, la medicina y la astronomía. Es posible ajustar la geometría fractal y los parámetros eléctricos para adaptarse a las necesidades de una aplicación específica. En este trabajo se aplicaron métodos numéricos para obtener las propiedades electromagnéticas de antenas de Peano en distintos puntos de su estructura, posteriormente se aplicó programación dinámica para obtener ecuaciones que describen el comportamiento eléctrico de estas antenas.

Mediante el Método de Momentos es posible obtener las propiedades electromagnéticas de una cantidad significativa de antenas de Peano en sus diversas iteraciones y en diversos puntos de alimentación. Es posible tratar estos datos para obtener las frecuencias de resonancia y los segmentos de frecuencias en los que el $VSWR \leq 2$.

Los datos obtenidos fueron usados para ser tratados por medio de regresión simbólica y se pudieron obtener ecuaciones de curvas que describen una relación entre el ta-

maño de la antena y las propiedades estudiadas (resonancia y $VSWR \leq 2$), en forma de una ecuación general de la forma $L = aF^{-1} + b$ no reportada en la literatura hasta ahora.

Para cada una de las iteraciones de la antena, el número de las curvas de resonancia obtenidas y estudiadas aumenta con el número de iteración de la antena, para una antena de Peano iteración 3 se pueden llegar a tener hasta 50 curvas de resonancia, cada una de ellas descrita por medio de una ecuación.

Para toda la banda UHF es posible por medio de los resultados aquí presentados encontrar una antena de Peano adecuada con un $VSWR \leq 2$ para su uso en una aplicación de radiofrecuencia. Para seleccionar la iteración de la misma, el punto de alimentación, y el ancho de la antena, es necesario consultar la aplicación de software disponible en Github [27] dado que los datos obtenidos son muy extensos para ser incluidos en forma escrita en este trabajo.

El método que se implementó aquí para obtener las propiedades y el tratamiento de las mismas y definir a partir de ello las ecuaciones de comportamiento, es susceptible de ser aplicado a otras estructuras de antenas fractales no reportadas en la literatura, así mismo, una vez que se ha demostrado que el estudio de las antenas en un sustrato de aire, es posible definir un sustrato distinto para una aplicación más práctica. Con esto se ha demostrado que es posible aplicar las herramientas de aprendizaje de máquina para dilucidar el comportamiento electromagnético de este tipo de antenas.

En el próximo capítulo, la atención se dirige hacia la generación de estructuras de antenas mediante algoritmos pseudoaleatorios y el estudio de sus propiedades. Se mostrará que este enfoque no convencional reveló nuevos comportamientos, llevando a la creación de antenas con propiedades interesantes. En este capítulo, se descubrieron los patrones emergentes, las propiedades y las potenciales aplicaciones de estas antenas generadas por algoritmos pseudoaleatorios.

Fenómeno dinámico: Antena autoevitable

3.1. Antecedentes

En esta parte del trabajo, se han estudiado las antenas microstrip inspiradas en la estructura de dipolo con un ingrediente aleatorio en el diseño tal que existe un efecto de auto-evitación para la geometría de la antena, efecto que se obtiene mediante el algoritmo de backtracking. A continuación, un sistema Lindenmayer (sistema L)[60–62] codifica las llamadas SA-antena para su posterior uso en un algoritmo genético.

Se utilizó el Método de los Momentos (MoM) [63, 64] en antenas SA metálicas de 1mm de anchura, con aire como sustrato, y con una línea de alimentación microstrip de $50\ \Omega$. Hay que tener en cuenta que se pueden elegir muchos materiales como sustratos en el modelo. Sin embargo, como el objetivo no es estudiar el efecto de los diferentes sustratos en el rendimiento de la antena, se elige aire para acelerar los cálculos numéricos (se han simulado 150.000 antenas) y se centra en el objetivo: la influencia de la geometría del diseño en el rendimiento de las antenas.

Para una implementación física del método, es posible crear la antena en un sustrato de material específico. Hay que tener en cuenta que en este trabajo se trata de una base de datos con información sobre una gran cantidad de antenas ya que, en general, los diseños de antenas son reportados uno por uno en la literatura. Además, aquí se presenta una ecuación que relaciona un grupo de antenas con esta geometría, el rango de frecuencias donde $VSWR \leq 2$ y el tamaño L del grupo de antenas, como criterio de optimización. El enfoque estudia, mediante algoritmos genéticos, las SA-antenas con frecuencias $VSWR \leq 2$ como objetivo de diseño de la antena.

En esta tesis se simulan las propiedades VSWR de 5.000 antenas SA con longitudes L de 0,1m a 0,4m, aumentando L en 0,01m para producir una secuencia de geometrías. Se simularon las propiedades de VSWR a diez frecuencias elegidas al azar dentro del rango UHF y se analizan los datos de las 150.000 antenas simuladas en total. La literatura informa de muchos métodos de optimización para diseñar antenas; la pérdida de retorno S_{11} (véase, por ejemplo, Li et al. [65], Zeghdoud et al.[66], Zaman et al [67], Wakrim et al. [68], Liu[69], Johnson et al.[70], Kaur et al.[71], Fertas et al.[72]), la

ganancia y el ancho de banda (Wang et al [73]) y la VSWR (Yamamoto et al.[74] , Werner et al.[75]), entre otros. En este trabajo se opta por minimizar la VSWR.

3.2. Geometría de la SA-antena mediante el algoritmo de Backtracking.

El primer paso es crear una codificación adecuada para la descripción de la estructura de la antena que se requiere generar, tal codificación debe tener las siguientes características:

- Describir la longitud de la antena y poder ser modificada para generar distintos tamaños
- Colocar el punto de alimentación arbitrariamente en cualquier punto de la longitud de la antena para la creación del dipolo.
- Ser apta para aplicar los pasos de; mutación, recombinación o cruzamiento, del algoritmo genético canónico.

Teniendo estos puntos en cuenta, se recurrió al Sistema-L (Sistema Lindenmayer) modificado para la codificación de la geometría de una antena.

- $V=\{*,F,+,-\}$, es el alfabeto de la gramática. En este contexto el símbolo 'F' genera un paso hacia adelante en el apuntador del programa de tortuga, el símbolo de la cadena '+' hace que al apuntador gire a la izquierda 90 grados, el símbolo '-' hace que gire a la derecha en 90 grados y finalmente el símbolo '*' indica la ausencia de algún giro.

El tamaño de la antena es directamente proporcional al numero de F's que se presenten en la cadena, para este caso el puntero de tortuga avanza 1mm cada vez que se lea una 'F' de la cadena, por lo tanto, una cadena que contenga 100 símbolos 'F' describe una curva que tiene una longitud de 100mm. También se definió la anchura de la curva de 1mm.

Para la generación de la cadena del Sistema-L es posible obtenerla de forma totalmente aleatoria. Sin embargo, al hacerlo de esta manera, el trazo de la curva es muy probable que se cruce consigo mismo. Como ejemplo de ello se tiene la cadena:

F*F-F+F+F+F-F*F-F+F-F*F+F-F*F*F+F+F*F+F-F-F-F-F+F*F*F-F*F*F+F+F*F*F*F+F+F+F-F-F-F+F+F+F*F*F*F*F*F*F*F*F-F-F-F+F*F+F+F*F-F-F*F-F*F*F*F-F*F-F+F+F-F-F-F+F+F*F+FF*F*F*F-F+F-F+F*F-F*F+F*F*F+F*F+F-F+F+F*F*F+F-F*F-F+F*F+F-F+F-F+F-F-F*F*F*F-F+F+F*F*F+F*F-F*F-F+F+F+F*F-F+F+F*F-F*F+F*F*F*F*F-F-F+F+F+F*F-F*F*

3. FENÓMENO DINÁMICO: ANTENA AUTOEVITABLE

- La cadena es interpretada por un puntero de tortuga, este contiene un pila de posición que partiendo de las coordenadas $(x,y)=(0,0)$ del plano cartesiano obtiene el recorrido del trazo siguiendo los símbolos de la cadena, en cada nuevo salto se hace una búsqueda del nuevo punto coordinado en la pila, si no se encuentran coincidencias se procede al punto 2. Si en la pila se localiza un punto anteriormente recorrido entonces el último salto de la cadena es anulado, los últimos dos símbolos de la cadena son eliminados y se regresa al punto 2, en donde se elige una camino diferente, en caso de que todas los caminos sean recorridos y sigue el cruce del trazo, entonces se retrocede al penúltimo punto y se recorre otro camino.

En la Figura 4.2 se puede ver un diagrama con los pasos en detalle del método de Backtracking.




Figura 3.2: Diagrama de flujo del algoritmo de backtracking utilizado en este artículo.

En la Figura 4.3 se muestran algunas geometrías de antenas de distintos tamaños y su correspondientes impedancias calculadas. En la Figura 4.3(b) se tiene la geometría




Figura 3.3: Ejemplos de antenas con geometría autoevitables, en las Figuras correspondientes de a la impedancia, la línea azul describe la propiedad de resistencia y la línea naranja la reactancia, las Figuras a) $L = 10$ cm con su resistencia y reactancia, b) $L = 20$ cm con su resistencia y reactancia, c) $L = 30$ cm con su resistencia y reactancia, y d) $L = 40$ cm con su resistencia y reactancia.

3. FENÓMENO DINÁMICO: ANTENA AUTOEVITABLE




Figura 3.4: a) Antena con L de 35 cm y en b) su correspondiente impedancia, c) Antena con L de 35 cm y en d) su correspondiente impedancia [5].

de una antena de 10cm con su correspondiente impedancia en ??, en 4.3(c) de 20 cm y su impedancia en 4.3(c), en 4.3(e) de 30cm con su impedancia en 4.3(f) y finalmente en la 4.3(g) una antena con un L de 40cm y su impedancia calculada en 4.3(h).

Como puede observarse, las impedancias de las antenas de distinto tamaño son diferentes entre si, como cabría de esperar, sin embargo, la impedancia de antenas del mismo tamaño pero con la geometría distinta también poseen impedancias diferentes, en las Figuras 4.4(a) y 4.4(c) se muestran dos antenas con una longitud de 36cm y como puede apreciarse en las Figuras 4.4(b) y 4.4(d) que son sus correspondiente impedancias, el comportamiento de sus impedancias son distintas a pesar de tener la misma longitud.

En la Figura 4.5(a) se muestran en puntos azules los valores del logaritmo de base 10 del VSWR, para el grupo de antenas con un tamaño $L=10$ cm, se usa el logaritmo por que a veces los valores de esta propiedad pueden diferir en mas de dos ordenes de magnitud, en total 50 000 datos para todo el conjunto de antenas en este caso para L de 10cm.

Como se aprecia, existe un patrón en la propiedad VSWR, mostrándose un mínimo, la linea naranja corresponde al logaritmo de base 10 del valor de 2 y puede verse que múltiples valores caen debajo de esa linea en el mínimo. Para poder sistematizar la localización de ese mínimo así como el rango en que los puntos caen debajo del VSWR




Figura 3.5: Datos de $\log(\text{VSWR})$ de 5000 antenas con un tamaño L de 10cm (puntos en azul), se muestra en verde la curva resultado de la suma de senos $\log(\text{VSWR}) = a_1 \text{sen}(b_1 F + c_1) + a_2 \text{sen}(b_2 F + c_2) + a_3 \text{sen}(b_3 F + c_3) + a_4 \text{sen}(b_4 F + c_4) + a_5 \text{sen}(b_5 F + c_5) + a_6 \text{sen}(b_6 F + c_6) +$, además se muestra el mínimo local de la curva que se encuentra a 1929.73 MHz marcada con la línea en negro.

= 2, se procedió en primer lugar a calcular una curva que se ajuste lo mejor posible a la distribución de datos en la gráfica.

Para ello se eligió una función de suma de senos que es de la forma: $\log(\text{VSWR}) = \sum_{n=1}^j a_n \text{sen}(b_n F + c_n)$, donde los coeficientes a_n, b_n, c_n se determinan numéricamente.

En la Figura 4.5(a) la función de suma de senos genera la curva en color verde, calculando numéricamente se encuentra el mínimo y este se marca con la línea negra y que sucede a 1929.73 MHz. El número de mínimos que se calculan, se utilizan como argumento del número de grupos que se esperan obtener por el algoritmo de agrupamiento.

Los datos con un VSWR menor a 2 son separados y alimentados a un algoritmo de agrupamiento, en este caso se optó por DBSCAN donde el parámetro ϵ ¹ (distancia máxima de agrupamiento para considerar que dos elementos forman parte de un mismo grupo) y el número mínimo de puntos para que una región sea considerada densa se asignan de forma aleatoria. Se crean 20 ejecuciones del algoritmo sobre el conjunto de datos y se desechan aquellas en donde difiera el número de grupos encontrados del número de mínimos encontrados.

¹Note por favor que ϵ en este contexto se refiere al parámetro de agrupamiento del algoritmo, la misma variable puede representar la permitividad del medio en el contexto de antenas

3. FENÓMENO DINÁMICO: ANTENA AUTOEVITABLE

Para el caso de ejemplo de el grupo de 10 cm, en la Figura 4.6(a) se muestra el agrupamiento obtenido por el algoritmo DBSCAN con los datos en color rojo, siendo que el objetivo es obtener un solo grupo (por existir solo un mínimo). En la Figura 4.6(b) se muestran los datos originales en azul, los puntos agrupados por DBSCAN en rojo, de estos datos se busca aquel en cuya frecuencia sea la más baja y por lo tanto el inicio del rango es en 1687.90MHz y finaliza en 2197.60MHz.




Figura 3.6: VSWR de 200 antenas con un tamaño $L = 10\text{cm}$: 4.6(a) se observa el agrupamiento por DBSCAN de datops con $VSWR \leq 2$ (rojo) 4.6(b) Datos de VSWR (azul), ajuste numérico que describe el comportamiento de los datos (verde), limite inicial y final de los datos $VSWR \leq 2$ (violeta) , puntos agrupados en el primero mínimo (rojo) y el mínimo calculado por medio de la curva de comportamiento (negro)

En el siguiente caso, se toman los datos de las antenas de 20cm, siguiendo los procedimientos anteriormente descritos, en la Figura 4.7(a) se puede observar la línea verde que describe el comportamiento de los datos con la función de suma de senos, el primer mínimo está en 1081.08MHz, también se puede observar en la parte derecha que existe un mínimo más allá de los 3000 MHz que es el límite de la banda UHF de estudio. En los casos en que se presenta esta situación el mínimo se establece a los 3000MHz. En la Figura 4.7(b) se muestran los datos agrupados por medio de DBSCAN en color rojo para el primer conjunto y cyan para el segundo.

Con el grupo de antenas con un tamaño $L=20\text{ cm}$, el rango de valores del primer rango de datos de $VSWR \leq 2$, van desde 903.30MHz a 1177.70MHz y en el segundo grupo este rango inicia en 2640.10 MHz y termina en 2999.90MHz. Estos rangos se encuentran marcados en la Figura 4.8 en líneas verticales violetas así como los puntos definidos del agrupamiento por DBSCAN, se pueden apreciar que aún cuando la mayor parte de los agrupamientos se encuentran en los respectivos mínimos, existen puntos aislados con un $VSWR \leq 2$ sin embargo, los mismos no se han asociado a ninguno de los dos grupos por el algoritmo de agrupamiento.

Finalmente, se incluye los datos de la población de antenas con un tamaño $L = 40\text{cm}$,




Figura 3.7: Datos de VSWR de 5000 antenas con un tamaño L de 20cm: 4.7(a) primer mínimo destacado con la línea vertical (negro), 4.7(b) $\text{VSWR} \leq 2$ agrupados por medio de DBSCAN

en la Figura 4.9(a) se muestra la línea de ajuste de la función de suma de senos, así como los mínimos a: 627.03MHz, 1610.81MHz y 2559.46 MHz. En la Figura 4.9(b) se muestra el resultado del agrupamiento de datos por DBSCAN. Los rangos de los agrupamiento se muestran en la Figura 4.10(a) y en la Figura 4.10(b) se muestra el conjunto de datos agrupados resultantes de DBSCAN.

Se procedió a graficar todos los rangos de los grupos obtenidos de todos los tamaños de antenas desde 10cm a 40cm como se muestra en la Figura 4.11 de acuerdo a los siguientes puntos:

- Para el primer grupo, la frecuencia en que inicia se destaca por un triángulo amarillo, el final con un triángulo violeta, y el área entre ellos se rellena de color rojo.
- Para el segundo grupo, la frecuencia en que inicia se destaca por un cuadrado amarillo y el final con un cuadrado violeta y el área entre ellos se rellena de color verde.
- Para el tercer y último grupo, la frecuencia en que inicia se destaca por un rombo amarillo y el final del grupo por medio de un rombo violeta.

En la Figura 4.11 puede apreciarse que los grupos a pesar de haber sido obtenidos de datos de antenas generadas con estructuras estocásticas autoevitables describen patrones de comportamiento. Las frecuencias a las que el $\text{VSWR} \leq 2$ solo es alcanzado en determinadas franjas correspondientes a determinado tamaños de antenas. El gráfico de la Figura 4.11 por sí mismo es útil para poder encontrar un tamaño adecuado de antena para determinada frecuencia, y como se puede ver, para que una antena pueda tener la propiedad del $\text{VSWR} \leq 2$ en múltiples frecuencias es necesario que para un determinado tamaño de antena las frecuencias deseadas estén contenidas en algunos de las franjas

3. FENÓMENO DINÁMICO: ANTENA AUTOEVITABLE




Figura 3.8: Datos de simulación de VSWR de 5000 antenas con un tamaño L de 20cm , los límites de los rangos de datos de $VSWR \leq 2$ están delimitados por líneas de color púrpura, en este caso los dos grupos obtenidos por medio de DBSCAN se muestra en puntos de color rojo y cyan.

de colores de la Figura 4.11.

Por ejemplo, se necesita que una antena pueda ser usada para bluetooth a una frecuencia de 2400 MHz y también que pueda ser usada para la frecuencia de 900 MHz de Internet inalámbrica, entonces en el gráfico 4.11 se marcan las dos frecuencias con una línea que recorre de izquierda a derecha todos los tamaños, tal como muestra en la Figura 4.11, la frecuencia de 2400 MHz solo es posible alcanzarla en los grupos dos y tres, y la de 900MHz sólo con el primero grupo. A partir de aquí para la frecuencia de 2400 MHz se toman todos los tamaños válidos de antenas, en este caso se enmarcan con un cuadro color magenta, se procede del mismo modo para la frecuencia de 900 MHz y en la gráfica se muestran los tamaños válidos enmarcados en el cuadro cyan. Los tamaños comunes a las dos frecuencias se resaltan en la línea gris que inicia en 22cm y termina en 27.5cm aproximadamente, es decir, que una antena de las características estudiadas debería tener un tamaño entre esos dos límites de la antena hay que encontrar la geometría adecuada.

Para determinar con mayor exactitud los tamaños de las antenas, se procedió a obtener ecuaciones que describan mejor que el método gráfico los límites de los grupos con relación al tamaño de las antenas. Para ello se usó la programación de algoritmos genéticos para ajustar funciones a los límites de los rangos. Por medio de GPLEARN se procedió a la búsqueda de funciones, encontrándose que la mejor función que se ajusta es:

3.3 Algoritmo genético aplicado en la obtención de una antena sintonizada




Figura 3.9: Datos de VSWR de 500 antenas con un tamaño L de 40cm: 4.9(a) 3 mínimos encontrados a lo largo de la curva, 4.9(b) detalles de la agrupación por medio de DBSCAN de los $VSWR \leq 2$ alrededor de los mínimos antes calculados.




Figura 3.10: Datos de VSWR de 5000 antenas con un tamaño L de 40 cm: 4.10(a) líneas de rangos donde el $VSWR \leq 2$, 4.10(b) datos de $VSWR \leq 2$ agrupados por medio de DBSCAN alrededor de los mínimos.

$$F = 299.792458(aL + b)^{-1}$$

en donde los parámetros a y b pueden obtenerse de la Tabla 4.1:

Con estas ecuaciones es posible definir de forma mas precisa los tamaños adecuados de antenas para cualquier frecuencia en el rango UHF.

3.3. Algoritmo genético aplicado en la obtención de una antena sintonizada

Por ejemplo, se elige 0.23m; entonces, $L=0.23m$ se introduce en nuestros algoritmos genéticos para producir la geometría y calcular mediante MoM todas las propiedades de una antena multibanda que use las frecuencias de 900MHz y 2400MHz.




Figura 3.11: Resultado de la tabulación de los rangos de todas las simulaciones de antenas donde el $VSWR \leq 2$ [6]

En el algoritmo genético de la Figura 4.12 , realizamos los siguientes pasos:

1. Inicialización. Se genera una población inicial de antenas SA, se propusieron 100 antenas de forma arbitraria. En este punto se genera el archivo MATLAB para su procesamiento.
2. Validación. El archivo MATLAB generado contiene: la geometría de la antena descrita por el mallado para aplicar el MoM y además el programa para calcular sus propiedades electromagnéticas. Las características de la antena son verificadas y se guarda en una base de datos tanto los valores obtenidos como la cadena del Sistema-L que genera la estructura de la antena.
3. Selección. De la base de datos se eligen dos de las cadenas de Sistema-L cuyas propiedades electromagnéticas de las antenas que generan se aproximen a las características deseadas. Estas cadenas serán la base para posteriormente hacer cruce y mutación.
4. Recombinación o cruce. En este paso se eligen dos puntos en la longitud de la cadena y los segmentos internos de las cadenas se intercambian. Las nuevas cadenas son interpretadas en las nuevas geometrías de las mismas, si son válidas las geometrías es decir, que no se cruzan consigo mismo, entonces se procede a la mutación.
5. Mutación. Obtenidas las cadenas por cruce, se elige aleatoriamente un símbolo de cada cadena y se intercambia, si el símbolo es '+' por un '-', y viceversa. El

n	símbolo	a	b
1	▲	1.36997884	0.05144089
2	▲	1.08977023	0.03464065
3	■	0.51048471	0.01307945
4	■	0.38742615	0.01704121
5	◆	0.31175580	0.00645883
6	◆	0.24090841	0.01554903

Tabla 3.1: Parámetros de las curvas que se ajustan a los límites de los rango obtenidas por medio de GPLearn para las curvas en la Figura 4.11

símbolo '*' puede intercambiarse por un '+' o '-' con un 50 % de probabilidades. El símbolo F no se modifica. Las cadenas resultantes se interpretan geométricamente para que generen una antena-SA válida.

La Figura 4.13 muestra la geometría de una antena SA obtenida en la iteración 7773 del algoritmo genético de la Figura 4.12, con el punto de alimentación en el centro de la trayectoria de la antena SA. Para abreviar, la llamaremos antena 7773. La Figura 4.14 muestra el VSWR de la antena 7773 en toda la banda de UHF. La línea de VSWR igual a dos, en naranja, muestra que hay dos mínimos: a) 927.55 MHz con un ancho de banda (BW) de 6.7166 %, y b) 2419.15 MHz con un BW de 2.4926 %. Por lo tanto, según lo deseado, utilizando nuestro enfoque, podemos proponer una antena SA con dos frecuencias de transmisión: a) 900 MHz con una VSWR de 1,8440 y b) 2400 MHz con una VSWR de 1.5003.

Por último, la Figura 4.15a muestra la directividad de la antena 7773 para la frecuencia de 900 MHz, donde $VSWR \leq 2$ y la Figura 4.15b muestra la directividad para 2400MHz, donde $VSWR \leq 2$ también.

3.4. Discusión y conclusiones preliminares

La propuesta aquí descrita puede convertirse en una estrategia de diseño racional para la miniaturización de las antenas, proporcionando así un diseño de menor coste. Está claro que la optimización de cualquier antena SA desarrollada es un aspecto esencial de este trabajo; esto es para lograr el rendimiento de comunicación deseado. Aquí, se aborda esta cuestión desde un punto de vista novedoso que implica el diseño de muchas antenas SA.

En este trabajo, se han introducido con éxito varias convenciones optimizadas de antenas SA. En primer lugar, se establece L fijo, a continuación, por los datos representados como en la Figura 4.11 (para $L = 0.36\text{m}$ como ejemplo), se obtienen los valores




Figura 3.12: Diagrama de flujo del algoritmo genético utilizado en este trabajo para producir la antena multibanda Figura 4.13. [6]




Figura 3.13: La antena SA generada por algoritmos genéticos (iteración 7773), a saber, la antena 7773, con una $VSWR \leq 2$ que transmite en dos frecuencias diferentes: 900MHz y 2400MHz, $L=0,23m$. El El cuadro resaltado en rojo es el punto de alimentación de la antena. El pequeño cuadrado negro está colocado sólo como referencia y tiene un tamaño de 1mm x 1mm [6].

simulados de $\log(VSWR)$ frente a la frecuencia. Por lo tanto tenemos dos opciones; a) se elige una frecuencia para la transmisión y recepción de la antena, entonces el valor óptimo de (rango de) $VSWR$ óptimo, o b) se elige un (rango de) valor mínimo particular de $VSWR$, entonces se calcula el (rango de) frecuencia óptimo para la recepción y la transmisión.

En segundo lugar, se establece la condición $VSWR \leq 2$ y se obtiene la frecuencia frente a los valores simulados de longitud L , de nuevo tenemos dos opciones; c) Establecer el (rango de) longitud L fijo y buscar la frecuencia óptima de recepción y transmisión de la antena, y d) elegir una frecuencia de recepción y transmisión, entonces la longitud (rango de) óptima L viene dada por nuestro modelo. Este último criterio (d) es quizás el enfoque de optimización más común para el diseño de antenas. Estos criterios y otros casos de interés pueden construirse directamente sobre los datos ya producidos en este trabajo y disponibles a petición. Se emplean con éxito un algoritmo genético, la programación genética y un código MoM electromagnético numérico para diseñar antenas SA compactas y multibanda. Conjeturamos que nuestro enfoque produce diseños de antenas más eficientes que los enfoques aleatorios tradicionales.

Además, se muestra cómo generar dipolos SA multibanda aplicando algoritmos genéticos ya que una antena SA con $VSWR \leq 2$ es necesaria para proponer nuevas antenas de buen comportamiento.

Por último, se presenta una ecuación que describe los nuevos patrones reportados aquí; esto constituye la principal contribución del trabajo. Se tiene la intención de utilizar algoritmos computacionales como backtracking y las implementaciones aleatorias para generar geometrías de antenas SA-antenas más complejas para futuras investigaciones.

3. FENÓMENO DINÁMICO: ANTENA AUTOEVITABLE




Figura 3.14: VSWR de la antena 7773 en función de la frecuencia en la banda UHF. Se representan el valor mínimo de VSWR y el ancho de banda. La línea naranja corresponde a $\text{VSWR}=2$ [6].




Figura 3.15: Directividades de la antena-7773 en dos frecuencias, a) 900 MHz; b) 2400MHz. [6]

Conclusiones

Una red neuronal es un tipo de algoritmo de aprendizaje automático que se inspira en la estructura y el funcionamiento del cerebro humano. Está formada por un gran número de nodos interconectados llamados neuronas artificiales, que se organizan en capas. Una forma de utilizar una red neuronal es imputar o completar los datos que pueden faltar en un conjunto de medidas experimentales. Para ello, la red neuronal se entrena con un conjunto de datos que incluye esas medidas experimentales. La red neuronal puede utilizar los patrones y relaciones aprendidos de las observaciones para hacer conjeturas sobre los valores que no están en el conjunto de datos de entrenamiento. Este proceso se conoce como "imputación de datos", en este trabajo se realizó exitosamente esta imputación sobre datos experimentales de la formación de hidratos de metano obteniendo datos en rangos que el experimento original no ha cubierto.

La regresión simbólica es una técnica que utiliza algoritmos evolutivos para descubrir ecuaciones matemáticas que describan un conjunto de datos determinado. Sin embargo, el éxito de la regresión simbólica para descubrir fórmulas empíricas puede depender de factores como la complejidad de la ecuación buscada y la calidad del conjunto de datos. Se ha utilizado en diversos campos para descubrir fórmulas empíricas, como la física, la química y la ingeniería.

En este trabajo se aplicó esta técnica exitosamente en varias partes de la investigación; obteniendo una formula para la velocidad de crecimiento de hidratos de metano, para la descripción de las curvas de resonancia de antenas de Peano en sus tres iteraciones y en varios anchos de antena con múltiples puntos de alimentación, también para la obtención de las curvas de VSWR para las mismas antenas fractales de Peano. Además para las antenas con geometría aleatoria- autoevitables se obtuvieron ecuaciones que describen el comportamiento de las propiedad $VSWR \leq 2$.

Los algoritmos genéticos (AG) se han utilizado en el diseño de antenas para sistemas de comunicación inalámbricos. La técnica consiste en utilizar algoritmos evolutivos para optimizar los parámetros de una antena, como su forma, tamaño y ubicación, con el fin de lograr el rendimiento deseado. Los estudios teóricos han demostrado que los AG son capaces de explorar eficazmente el espacio de diseño y encontrar soluciones casi óptimas

4. CONCLUSIONES

para los problemas de diseño de antenas. En concreto, los AG se han aplicado al diseño de diversos tipos de antenas, como antenas de parche, antenas microstrip y arreglos de antenas. El uso de los AG en el diseño de antenas permite la exploración eficaz de espacios de diseño grandes y complejos, lo que hace posible encontrar soluciones difíciles de obtener con los métodos de optimización tradicionales. En este trabajo se aplicaron exitosamente estos algoritmos para el sobre estructuras de dipolos microstrip con una estructura aleatoria-autoevitable para obtener una antena con capacidad multibanda en dos frecuencias de uso comercial y reportadas adecuadamente en la literatura.

Trabajo futuro

Una de las direcciones más prometedoras para el trabajo futuro radica en la aplicación de la técnica de imputación mediante redes neuronales, desarrollada en el presente estudio, a nuevos conjuntos de datos experimentales. Esta técnica ha demostrado ser eficaz para tratar con datos faltantes, permitiendo una interpretación más precisa y confiable de los datos experimentales en este trabajo. Al aplicar este enfoque a nuevos conjuntos de datos, se espera ampliar su utilidad y validar su efectividad en diversos contextos. Dado que la imputación de datos es un desafío común en una amplia gama de campos de investigación, el potencial de impacto de esta técnica es inmenso.

Además, también se buscará refinar y mejorar la técnica de imputación. Con el aprendizaje acumulado en su aplicación y con la adquisición de nuevos datos experimentales, se espera que las redes neuronales puedan optimizarse y adaptarse aún más, resultando en una herramienta de imputación aún más precisa y poderosa.

Además de la aplicación de la técnica de imputación a nuevos conjuntos de datos, se planea extender las técnicas desarrolladas en el estudio de antenas a otros tipos de antenas y estructuras. Entre las antenas de interés se encuentran aquellas con estructura de curvas fractal de Wunderlich, curvas fractales de Hilbert y curvas fractales de Moore. Estas estructuras, aunque menos convencionales, presentan características únicas que pueden ofrecer una nueva perspectiva en el diseño y la funcionalidad de las antenas.

En esta extensión, el objetivo es no solo aplicar las técnicas desarrolladas sino también mejorar los resultados obtenidos, acercándolos aún más a la realidad. Una forma de lograrlo será mediante la inclusión de sustratos en las estructuras de antenas. Los sustratos pueden alterar significativamente las propiedades de las antenas, y su inclusión en los modelos permitirá una representación más realista del comportamiento de las antenas.

Resumen del Capítulo 2: Estudio del fenómeno dinámico de formación de hidratos de metano mediante el uso de Redes Neuronales y Algoritmos Genéticos

El primer capítulo de esta tesis doctoral abordó el estudio del fenómeno dinámico de formación de hidratos de metano, un proceso relevante con amplias implicaciones en campos como la geología, la química y la ingeniería de petróleo y gas.

El estudio empleó una metodología de dos etapas. En la primera etapa, se utilizó una serie de datos experimentales, derivados de una fuente científica publicada, como entrada para el entrenamiento de redes neuronales. El objetivo de este proceso fue la imputación de datos faltantes, aprovechando la capacidad de estas técnicas de aprendizaje automático para identificar patrones y relaciones complejas en los datos existentes. Una vez que los datos faltantes fueron imputados con éxito, se avanzó a la segunda etapa. En esta fase, se emplearon algoritmos genéticos para modelar el comportamiento del fenómeno de formación de hidratos de metano. Estos algoritmos, inspirados en los principios de la evolución natural, se utilizaron para buscar y optimizar una ecuación que describiera de la manera más precisa posible el comportamiento dinámico observado.

En este capítulo presentó una estrategia novedosa y eficaz para el estudio del fenómeno de formación de hidratos de metano, demostrando el valor del aprendizaje automático y la optimización basada en la evolución en el análisis de complejos procesos dinámicos. La metodología desarrollada tiene el potencial de ser aplicada a otros fenómenos similares, ampliando así su relevancia y utilidad en la investigación científica.

Resumen del Capítulo 3: Simulación y Análisis de Antenas con Estructuras de la Curva de Peano en la Banda UHF

El segundo capítulo de la tesis se centró en el estudio de antenas con estructuras de la curva de Peano. Mediante la simulación computacional, se analizaron las tres primeras iteraciones de estas estructuras de antena, evaluando varios puntos de simulación a lo largo de la estructura, en tres diferentes anchos de antena y con un tamaño lateral de antena variable.

6. RESUMEN

Los datos obtenidos de estas simulaciones fueron sometidos a un análisis y tratamiento exhaustivos. Se emplearon algoritmos genéticos para modelar y optimizar ecuaciones que describieran con precisión las propiedades de resonancia y la Relación de Onda Estacionaria de Voltaje (VSWR) de estas antenas a lo largo de la banda UHF. Este análisis cubrió un rango de tamaño de antena desde 0.01m hasta 0.1m.

Este estudio presentó un enfoque pionero en la simulación y análisis de antenas con estructuras de la curva de Peano. Los resultados obtenidos y las ecuaciones desarrolladas proporcionan una valiosa comprensión de las propiedades de estas antenas en la banda UHF, y podrían facilitar el diseño y la optimización de antenas en aplicaciones prácticas.

Resumen del Capítulo 4: Análisis y Optimización de Antenas con Estructuras Aleatorias para Aplicaciones Multibanda

El tercer capítulo de la tesis doctoral abordó el estudio de antenas con estructuras generadas aleatoriamente. Las dimensiones de estas antenas variaron a partir de un tamaño inicial, incrementando la longitud en 1cm para cada antena sucesiva.

Tras la simulación computacional de un amplio conjunto de estas antenas, se identificaron patrones de comportamiento distintivos que no serían evidentes en antenas con configuraciones lineales. Estos patrones fueron posteriormente analizados y modelados por medio de algoritmos genéticos, lo que permitió la formulación de ecuaciones que describen con precisión estas características.

Estas ecuaciones proporcionan una herramienta valiosa para determinar el tamaño óptimo de la antena para su uso en aplicaciones multibanda. Además, una vez que se seleccionó el tamaño de la antena, se utilizaron nuevamente los algoritmos genéticos para optimizar la estructura aleatoria de la antena.

Este capítulo, por tanto, proporciona un marco metodológico innovador para el análisis y optimización de antenas con estructuras generadas aleatoriamente. Los hallazgos resultantes tienen el potencial de mejorar el diseño y la funcionalidad de las antenas para aplicaciones multibanda.

Apéndice A

Tablas de datos

A.1. Apéndice A

	Peano iteración 1 0.25 mm				
curva	a	b	RMS	Min(F)	Max(F)
	[m MHz]	[$\times 10^{-5}$ m]	[$\times 10^{-7}$]	[MHz]	[MHz]
0	39.3092	61.0359	2292.47	390.3627	2668.6079
1	44.5263	46.9969	1570.46	441.6358	3000.2113
2	74.3279	4.3839	338.23	734.4907	2950.3644
3	85.6626	4.1398	205.87	846.4442	2933.6490
4	152.3098	53.4593	134.15	1512.2041	2888.9719
5	172.5254	-12.2380	18.02	1701.9094	2905.8590
6	188.3153	25.2616	15.28	1864.5450	2989.2240
7	220.0766	18.2876	45.99	2177.4833	2931.6419
8	230.9235	119.4539	16.02	2307.9361	2958.4236
9	265.3432	-145.7664	13.65	2583.4986	2991.2341
	Peano iteración 1 0.50 mm				
0	39.4893	90.5418	2711.02	392.2852	2686.0016
1	44.6579	73.6020	1593.60	443.0056	2654.1517
2	74.2489	17.3887	415.53	732.8566	2933.6087
3	85.5866	15.7786	340.64	844.6097	2918.2492
4	152.5458	90.2732	134.15	1516.3244	2899.9560
5	172.4732	-21.0105	15.19	1695.7440	2988.6418
6	188.3746	46.8244	13.77	1864.4980	2988.5377
7	220.7049	0.9298	55.73	2174.5757	2923.4956
8	230.8036	241.5736	59.59	2329.4279	2994.3050
9	264.9992	-269.3931	10.73	2543.3142	2938.0839
	Peano iteración 1 1.50 mm				
0	39.7111	142.6563	3320.47	398.4707	2897.3903
1	44.8145	122.2558	1824.30	448.9260	2827.6120
2	74.1533	45.2071	460.92	737.5908	2795.0774
3	85.4576	44.2684	575.10	849.9753	2995.0108
4	152.7063	168.5865	34.10	1537.5967	2976.0295
5	172.5326	-45.0220	100.71	1700.6099	2901.8698
6	188.4135	91.1013	2.61	1882.4571	2939.8708
7	221.4859	-42.3829	67.98	2183.6977	2936.4188
8	209.1765	1453.8268	0.00	2419.2963	2476.5837
9	299.8693	-2032.6858	0.00	2471.5819	2513.0073

Tabla A.1: Peano_1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.125 (1/8) de la longitud S , para tres anchuras de antena diferentes.

	Peano iteración 1 0.25 mm				
curva	a [m MHz]	b [$\times 10^{-5}m$]	RMS [$\times 10^{-7}$]	Min(F) [MHz]	Max(F) [MHz]
0	39.2984	60.2803	2263.68	390.2295	2666.7312
1	55.1491	19.2913	144.22	545.6984	2893.2110
2	74.2841	2.8732	374.15	733.9553	2947.0243
3	109.6878	-93.3115	1327.77	1073.8799	2876.7740
4	152.2292	59.2135	129.48	1512.2698	2890.6114
5	163.7704	-21.0098	63.88	1614.1744	2953.0878
6	188.5018	28.6246	24.92	1867.0054	2993.7604
7	222.1877	-29.5786	9.87	2188.0637	2941.1202
	Peano iteración 1 0.50 mm				
0	39.4761	89.4420	2675.07	392.1154	2683.3688
1	55.1587	29.2798	40.89	545.0028	2872.0267
2	74.1964	15.3328	462.03	732.1994	2929.3659
3	108.8322	-107.8558	2015.46	1061.6008	2982.0320
4	152.3810	108.8859	33.21	1517.5458	2907.4338
5	163.7012	-46.7480	27.29	1605.4240	2924.8411
6	188.6072	50.8967	28.07	1867.5426	2994.1309
7	221.8565	-45.9104	47.33	2175.9801	2999.8135
	Peano iteración 1 1.00 mm				
0	39.6948	140.9701	3270.51	398.2441	2893.1110
1	55.1581	66.5846	4979.25	550.1723	2999.2615
2	74.0896	42.3135	520.57	736.7560	2789.9076
3	107.6416	-119.5877	4209.90	1053.6961	2987.5292
4	151.8770	244.1790	3221.91	1540.8696	2783.5914
5	164.2686	-115.3645	6879.40	1609.5107	2827.5240
6	188.7243	94.4362	84.30	1886.1424	2946.1252
7	221.2642	-55.5042	750.31	2179.2406	2928.1693

Tabla A.2: Peano.1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.3125 (o 5/16) veces la longitud S , para tres anchuras de antena diferentes.

Peano iteración 1 0.25 mm					
curva	a	b	RMS	Min(F)	Max(F)
	[m MHz]	$[\times 10^{-5}m]$	$[\times 10^{-7}]$	[MHz]	[MHz]
0	39.2973	60.1865	2260.95	390.2147	2666.4921
1	66.8128	6.0734	258.24	660.3189	2882.5796
2	74.2708	2.5174	387.44	733.8011	2946.1433
3	85.4541	-17.1844	490.79	842.6752	2906.4613
4	151.9124	61.2614	109.78	1509.4419	2999.7396
5	171.3972	-61.6635	113.09	1682.6356	2962.1881
6	188.5107	43.1025	15.55	1869.7816	3000.8257
7	198.9010	-34.8369	48.43	1957.7584	2942.4918
8	232.0882	108.5704	34.83	2317.0356	2969.1677
9	259.6622	-34.6057	1.63	2555.8315	2964.3166
Peano iteración 1 0.50 mm					
0	39.4748	89.2827	2670.79	392.0961	2683.0132
1	66.7536	7.9394	475.26	658.2646	2852.6715
2	74.1800	15.0163	477.94	732.0183	2928.4276
3	85.2802	-4.0586	784.99	840.0448	2890.0757
4	152.0812	109.2142	64.27	1514.5937	2901.7609
5	171.0650	-85.2927	131.60	1671.4105	2931.8296
6	188.4165	92.3221	80.57	1873.4121	2917.9108
7	198.7195	-71.0374	10.67	1944.2246	2913.3032
8	232.7732	178.4546	29.43	2334.3401	2995.1421
9	259.5831	-53.5902	0.26	2544.0365	2948.6041
Peano iteración 1 1.00 mm					
0	39.6932	140.7051	3268.41	398.2179	2892.4043
1	66.6550	38.9303	7085.54	663.3393	2939.2161
2	74.0705	41.9207	531.10	736.5356	2788.8789
3	84.9738	9.2774	7614.70	841.3910	2933.3147
4	151.6684	245.6978	2999.43	1539.9508	2884.1398
5	171.3063	-199.9093	10051.61	1660.0625	2888.8492
6	186.7243	274.7258	3953.39	1899.6371	2658.9099
7	199.4387	-167.7493	7788.20	1945.8511	2670.5862
8	232.6510	360.3901	937.80	2389.2274	2929.4060
9	258.8893	-99.6757	3333.82	2536.3259	2944.5777

Tabla A.3: Peano.1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.4375 (7/16) de la longitud S , para tres anchuras de antena diferentes.

A. TABLAS DE DATOS

Peano iteración 1 0.25 mm					
curve	a	b	RMS	Min(F)	Max(F)
	[m MHz]	$[\times 10^{-5}m]$	$[\times 10^{-7}m]$	[MHz]	[MHz]
0	39.2972	60.1786	2260.67	390.2134	2666.4728
1	76.0477	-3.0599	215.72	750.8984	2788.6502
2	117.7611	450.3067	5674.08	1218.6418	2655.2450
3	150.2310	-517.9883	7616.95	1409.4736	2733.5770
4	188.4530	28.9678	21.46	1866.5882	2993.1564
5	220.6946	-72.3041	75.68	2164.3177	2983.5970
6	270.0757	145.9924	2.14	2706.4349	2942.3151
7	299.2476	-107.8169	0.00	2924.3910	2982.6875
Peano iteración 1 0.50 mm					
0	39.4747	89.2690	2670.49	392.0943	2682.9818
1	75.9584	3.4937	672.08	748.7391	2986.3350
2	103.2134	2078.9249	516.22	1279.1509	1345.8464
3	183.4192	-3575.2250	918.78	1336.0216	1376.0724
4	188.5393	52.5854	21.02	1867.1871	2993.8708
5	219.7662	-92.3438	107.34	2145.7648	2953.1257
6	269.5047	311.0432	15.54	2739.1819	2981.6192
7	300.1823	-251.8570	0.00	2885.8529	2942.4280
Peano iteración 1 1.00 mm					
0	39.6542	147.8141	2036.90	398.2156	1680.1156
1	75.8239	21.3563	457.06	752.4315	1693.7680

Tabla A.4: Peano.1. Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.5 (o 1/2) veces la longitud S , para tres anchuras de antena diferentes.

Peano iteración 1 0.25 mm					
curva	a	b	RMS	Min(F)	Max(F)
	[m MHz]	$[\times 10^{-5}m]$	$[\times 10^{-7}]$	[MHz]	[MHz]
0	39.2973	60.1865	2260.95	390.2147	2666.4921
1	66.8128	6.0734	258.24	660.3189	2882.5796
2	74.2708	2.5174	387.44	733.8011	2946.1433
3	85.4541	-17.1844	490.79	842.6752	2906.4613
4	151.9124	61.2614	109.78	1509.4419	2999.7396
5	171.3972	-61.6635	113.09	1682.6356	2962.1881
6	188.5107	43.1025	15.55	1869.7816	3000.8257
7	198.9010	-34.8369	48.43	1957.7584	2942.4918
8	232.0882	108.5704	34.83	2317.0356	2969.1677
9	259.6622	-34.6057	1.63	2555.8315	2964.3166
Peano iteración 1 0.50 mm					
0	39.4748	89.2827	2670.79	392.0961	2683.0132
1	66.7536	7.9394	475.26	658.2646	2852.6715
2	74.1800	15.0163	477.94	732.0183	2928.4276
3	85.2802	-4.0586	784.99	840.0448	2890.0757
4	152.0812	109.2142	64.27	1514.5937	2901.7609
5	171.0650	-85.2927	131.60	1671.4105	2931.8296
6	188.4165	92.3221	80.57	1873.4121	2917.9108
7	198.7195	-71.0374	10.67	1944.2246	2913.3032
8	232.7732	178.4546	29.43	2334.3401	2995.1421
9	259.5831	-53.5902	0.26	2544.0365	2948.6041
Peano iteración 1 1.00 mm					
0	39.6932	140.7051	3268.41	398.2179	2892.4043
1	66.6550	38.9303	7085.54	663.3393	2939.2161
2	74.0705	41.9207	531.10	736.5356	2788.8789
3	84.9738	9.2774	7614.70	841.3910	2933.3147
4	151.6684	245.6978	2999.43	1539.9508	2884.1398
5	171.3063	-199.9093	10051.61	1660.0625	2888.8492
6	186.7243	274.7258	3953.39	1899.6371	2658.9099
7	199.4387	-167.7493	7788.20	1945.8511	2670.5862
8	232.6510	360.3901	937.80	2389.2274	2929.4060
9	258.8893	-99.6757	3333.82	2536.3259	2944.5777

Tabla A.5: Peano_1.Parámetros para las ecuaciones de frecuencia de resonancia, punto de alimentación situado a 0.4375 (7/16) de la longitud S , para tres anchuras de antena diferentes.

Bibliografía

- [1] C. F. Ma, G. J. Chen, and T. M. Guo, “Kinetics of hydrate formation using gas bubble suspended in water,” Science in China Series B-Chemistry, vol. 45, no. 2, pp. 208–215, 2002. [vii](#), [vii](#), [vii](#), [xi](#), [8](#), [9](#), [10](#), [11](#), [12](#), [13](#), [14](#), [15](#), [16](#), [20](#)
- [2] C.-Y. Sun, G.-J. Chen, C.-F. Ma, Q. Huang, H. Luo, and Q.-P. Li, “The growth kinetics of hydrate film on the surface of gas bubble suspended in water or aqueous surfactant solution,” Journal of Crystal Growth, vol. 306, no. 2, pp. 491–499, 2007. [vii](#), [vii](#), [vii](#), [xi](#), [8](#), [9](#), [10](#), [11](#), [12](#), [13](#), [14](#), [15](#), [16](#), [20](#)
- [3] R. Perez-Moroyoqui, O. Ibanez-Orozco, and S. Rodriguez-Romo, “An intelligent equation for methane hydrate growth kinetics,” MATHEMATICS AND COMPUTERS IN SIMULATION, vol. 192, pp. 19–32, FEB 2022. [vii](#), [vii](#), [vii](#), [vii](#), [vii](#), [viii](#), [viii](#), [viii](#), [viii](#), [viii](#), [10](#), [12](#), [15](#), [16](#), [17](#), [18](#), [19](#), [20](#), [21](#), [22](#), [23](#)
- [4] H. Lei, Y. Zhen, and B. Wu, “Equilibrium pt curve of methane hydrates in the presence of AlCl₃,” Chinese Science Bulletin, vol. 48, no. 1, pp. 53–56, 2013. [viii](#), [23](#)
- [5] O. I.-O. Rene Perez-Moroyoqui, Suemi Rodriguez-Romo, “Patterns of the radiation properties for peano antennas.” unpublished, 2022. [viii](#), [viii](#), [viii](#), [ix](#), [30](#), [33](#), [34](#), [46](#)
- [6] R. Perez-Moroyoqui, S. Rodriguez-Romo, and O. Ibanez-Orozco, “Genetic algorithm for the design of a multiband microstrip antenna with self-avoiding geometry obtained by backtracking,” INTERNATIONAL JOURNAL OF COMMUNICATION SYSTEMS. [ix](#), [x](#), [x](#), [x](#), [x](#), [52](#), [54](#), [55](#), [56](#)
- [7] Z. Rao, P. Tung, R. Xie, Y. Wei, H. Zhang, A. Ferrari, T. P. C. Klaver, F. Körmann, P. T. Sukumar, A. K. da Silva, Y. Chen, Z. Li, D. Ponge, J. Neugebauer, O. Gutfleisch, S. Bauer, and D. Raabe, “Machine learning-enabled high-entropy alloy discovery,” Science, 2 2022. [2](#)
- [8] H. Beyer and W. Walter, “Manual de Quimica Organica,” p. 980, 1987. [7](#), [8](#)
- [9] G. D. Holder, “Clathrate hydrates of natural gases, 2nd ed., revised and expanded. chemical industries series/73 by e. denny sloan, jr. marcel dekker, inc.: New york.

BIBLIOGRAFÍA

1998. 754 pages. ISBN 0-8247-9937-2,” Journal of the American Chemical Society, vol. 120, no. 43, p. 11212, 1998. [8](#)
- [10] D. N. Glew and M. L. Haggett, “Kinetics of formation of ethylene oxide hydrate. part II. incongruent solutions and discussion,” Canadian Journal of Chemistry, vol. 46, no. 24, pp. 3867–3877, 1968. [9](#)
- [11] J. S. Parent and P. Bishnoi, “Investigations into the nucleation behaviour of methane gas hydrates,” Chemical Engineering Communications, vol. 144, no. 1, pp. 51–64, 1996.
- [12] P. Englezos, N. Kalogerakis, P. Dholabhai, and P. Bishnoi, “Kinetics of formation of methane and ethane gas hydrates,” Chemical Engineering Science, vol. 42, no. 11, pp. 2647–2658, 1987.
- [13] P. Servio and D. Mahajan, “Kinetic reproducibility of methane production from methane hydrates,” Abstracts of Papers of the American Chemical Society, vol. 226, pp. U572–U572, 2003. [9](#)
- [14] A. H. Mohammadi, J. F. Martínez-López, and D. Richon, “Determining phase diagrams of tetrahydrofuran+methane, carbon dioxide or nitrogen clathrate hydrates using an artificial neural network algorithm,” Chemical Engineering Science, vol. 65, no. 22, pp. 6059–6063, 2010. [10](#)
- [15] A. H. Mohammadi and D. Richon, “Hydrate phase equilibria for hydrogen+water and hydrogen+tetrahydrofuran+water systems: Predictions of dissociation conditions using an artificial neural network algorithm,” Chemical Engineering Science, vol. 65, no. 10, pp. 3352–3355, 2010.
- [16] A. H. Mohammadi, V. Belandria, and D. Richon, “Use of an artificial neural network algorithm to predict hydrate dissociation conditions for hydrogen+water and hydrogen+tetra-n-butyl ammonium bromide+water systems,” Chemical Engineering Science, vol. 65, no. 14, pp. 4302–4305, 2020. [10](#)
- [17] G.-J. Chen and T.-M. Guo, “A new approach to gas hydrate modelling,” Chemical Engineering Journal, vol. 71, no. 2, pp. 145–151, 1998. [11](#)
- [18] G.-J. Chen and T.-M. Guo, “Thermodynamic modeling of hydrate formation based on new concepts,” Fluid Phase Equilibria, vol. 122, no. 1, pp. 43–65, 1996. [11](#)
- [19] J. Long and E. D. Sloan, “Quantized water clusters around apolar molecules,” Molecular Simulation, vol. 11, no. 2, pp. 145–161, 1993. [11](#)
- [20] J. Foroozesh, A. Khosravani, A. Mohsenzadeh, and A. Haghighat Mesbahi, “Application of artificial intelligence (AI) in kinetic modeling of methane gas hydrate formation,” Journal of the Taiwan Institute of Chemical Engineers, vol. 45, no. 5, pp. 2258–2264, 2014. [11](#), [21](#), [22](#)

-
- [21] J. H. v. d. Waals and J. C. Platteeuw, "Clathrate solutions," in Advances in Chemical Physics, pp. 1–57, John Wiley & Sons, Ltd, 2007. 11
- [22] A. Blum, Neural Networks in C++: An Object-Oriented Framework for Building Connectionist Systems. USA: John Wiley & Sons, Inc., 1st ed., 1992. 14
- [23] Z. Boger and H. Guterman, "Knowledge extraction from artificial neural network models," in 1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation, vol. 4, pp. 3030–3035 vol.4, 1997.
- [24] K. Swingler, Applying neural networks - a practical guide. Academic Press, 1996.
- [25] M. J. Berry and G. Linoff, Data Mining Techniques: For Marketing, Sales, and Customer Support. USA: John Wiley & Sons, Inc., 1997. 14
- [26] J. Anguera, A. Andújar, J. Jayasinghe, V. V. S. S. S. Chakravarthy, P. S. R. Chowdary, J. L. Pijoan, T. Ali, and C. Cattani, "Fractal Antennas: An Historical Perspective," Fractal and Fractional 2020, Vol. 4, Page 3, vol. 4, p. 3, jan 2020. 26
- [27] R. Perez-Moroyoqui, "Peanoantennas." <https://github.com/moroyoqui-UNAM/PEANOANTENNAS>, 2021. 27, 29, 31, 34, 36, 37, 39
- [28] Y. Huang and K. Boyle, Antenna Basics, pp. 107–127. 2008. 27
- [29] A. Simonič, "An extension of Lomonosov's Techniques to non-compact Operators," Trans. Amer. Math. Soc., vol. 348, pp. 975–995, 1996. 27
- [30] C. Balanis, "Antenna Theory: Analysis and Design, Fourth Edition," in John Wiley & Sons, Inc., 2016. 27
- [31] I. S. Bangi and J. S. Sivia, "Moore, Minkowski and Koch Curves Based Hybrid Fractal Antenna for Multiband Applications," Wireless Personal Communications, vol. 108, pp. 2435–2448, oct 2019. 27
- [32] J. Zhu, A. Hoorfar, and N. Engheta, "Peano antennas," IEEE Antennas and Wireless Propagation Letters, 2004. 28
- [33] Deepti Das Krishna, A. R. Chandran, and C. K. Aanandan, "A compact dual frequency antenna with Sierpinski gasket based slots," in 2007 European Microwave Conference, pp. 1078–1080, IEEE, 2007.
- [34] A. Reha, A. El Amri, and O. Benhammouch, "Cpw-fed dragon fractal antenna for uwb applications," in Lecture Notes in Electrical Engineering, vol. 397, pp. 423–429, Springer Verlag, 2017. 27
- [35] K. J. Vinoy, K. A. Jose, V. K. Varadan, and V. V. Varadan, "Hilbert curve fractal antenna: A small resonant antenna for VHF/UHF applications," Microwave and Optical Technology Letters, vol. 29, pp. 215–219, may 2001. 28
-

BIBLIOGRAFÍA

- [36] K. J. Vinoy, K. A. Jose, V. K. Varadan, and V. V. Varadan, "Resonant frequency of Hilbert curve fractal antennas," in IEEE Antennas and Propagation Society, AP-S International Symposium (Digest), vol. 3, pp. 648–651, 2001.
- [37] K. J. Vinoy, K. A. Jose, V. K. Varadan, and V. V. Varadan, "Hilbert curve fractal antennas with reconfigurable characteristics," in IEEE MTT-S International Microwave Symposium Digest, vol. 3, pp. 381–384, 2001.
- [38] S. R. Best, "A comparison of the performance properties of the Hilbert curve fractal and meander line monopole antennas," Microwave and Optical Technology Letters, vol. 35, pp. 258–262, nov 2002.
- [39] J. Romeu and S. Blanch, "A three dimensional Hilbert antenna," in IEEE Antennas and Propagation Society, AP-S International Symposium (Digest), vol. 4, pp. 550–553, 2002.
- [40] J. Anguera, C. Puente, and J. Soler, "Miniature monopole antenna based on the fractal hilbert curve," IEEE Antennas and Propagation Society, AP-S International Symposium (Digest), vol. 4, pp. 546–549, 2002.
- [41] J. Zhu, A. Hoorfar, and N. Engheta, "Bandwidth, cross-polarization, and feed-point characteristics of matched Hubert antennas," IEEE Antennas and Wireless Propagation Letters, vol. 2, pp. 2–5, 2003.
- [42] J. M. González-Arbesú, S. Blanch, and J. Romeu, "Are space-filling curves efficient small antennas?," IEEE Antennas and Wireless Propagation Letters, vol. 2, pp. 147–150, 2003. [28](#)
- [43] E. El-Khouly, H. Ghali, and S. A. Khamis, "High directivity antenna using a modified peano space-filling curve," IEEE Antennas and Wireless Propagation Letters, 2007. [28](#)
- [44] J. McVay and A. Hoorfar, "Miniaturization of top-loaded monopole antennas using Peano-curves," Proceedings - 2007 IEEE Radio and Wireless Symposium, RWS, pp. 253–256, 2007.
- [45] D. H. Werner, W. Kuhirun, and P. L. Werner, "The Peano-Gosper fractal array," IEEE Transactions on Antennas and Propagation, vol. 51, pp. 2063–2072, aug 2003. [28](#)
- [46] H. Oraizi and S. Hedayati, "Miniaturized UWB monopole microstrip antenna design by the combination of Giusepe Peano and Sierpinski carpet fractals," IEEE Antennas and Wireless Propagation Letters, vol. 10, pp. 67–70, 2011.
- [47] H. Oraizi and S. Hedayati, "Miniaturization of microstrip antennas by the novel application of the Giuseppe peano fractal geometries," IEEE Transactions on Antennas and Propagation, 2012.

- [48] M. R. da Silva, C. d. L. Nóbrega, P. H. d. F. Silva, and A. G. D'Assunção, "Stable and compact multiband frequency selective surfaces with peano pre-fractal configurations," IET Microwaves, Antennas & Propagation, vol. 7, pp. 543–551, may 2013.
- [49] A. Goyal, A. Alphones, M. F. Karim, L. C. Ong, and N. Nasimuddin, "A compact monopole fractal antenna for TV white space energy harvesting applications," IEEE Antennas and Propagation Society, AP-S International Symposium (Digest), vol. 2015-October, pp. 2437–2438, oct 2015.
- [50] G. Pal and N. Sharma, "Novel Design of Fractal Antenna using Giuseppe Peano Geometry for Wireless Applications," International Journal of Computer Applications, vol. 150, pp. 29–32, sep 2016.
- [51] N. Sharma, G. P. Singh, and V. Sharma, "Miniaturization of fractal antenna using novel Giuseppe peano geometry for wireless applications," 1st IEEE International Conference on Power Electronics, Intelligent Control and Energy Systems, ICPEICES 2016, feb 2017.
- [52] N. Vegesna, K. Yugandhar, D. V. Bharathi, and P. K. Varma, "Giuseppe peano fractal antenna for application in 'X' to 'KA' bands," Journal of Computational and Theoretical Nanoscience, vol. 16, pp. 1284–1288, apr 2019. [28](#)
- [53] C. Puente-Baliarda and R. Pous, "Fractal design of multiband and low side-lobe arrays," IEEE Transactions on Antennas and Propagation, vol. 44, no. 5, pp. 730–739, 1996. [28](#)
- [54] N. Cohen, "Fractal antenna applications in wireless telecommunications," Professional Program Proceedings of the Electronics Industries Forum, pp. 43–49, 1997.
- [55] D. H. Werner, R. L. Haupt, and P. L. Werner, "Fractal antenna engineering: the theory and design of fractal antenna arrays," IEEE Antennas and Propagation Magazine, vol. 41, pp. 37–59, oct 1999.
- [56] J. P. Gianvittorio and Y. Rahmat-Samii, "Fractal antennas: A novel antenna miniaturization technique, and applications," IEEE Antennas and Propagation Magazine, vol. 44, pp. 20–36, feb 2002.
- [57] J. Anguera, C. Puente, C. Borja, and J. Soler, "Fractal Shaped Antennas: A Review," Encyclopedia of RF and Microwave Engineering, apr 2005. [28](#)
- [58] The Mathworks, Inc., Natick, Massachusetts, MATLAB version (R2021b), 2021. [29](#)
- [59] T. Stephens, "gplearn." <https://gplearn.readthedocs.io/en/stable/>, 2000–2004. [29](#)

- [60] G. G. Chavka, “Beauty of fractals, design of fractal antennas,” in 2007 6th International Conference on Antenna Theory and Techniques, ICATT 07, pp. 76–81, 2007. [41](#)
- [61] J. Mishra and S. N. S. N. Mishra, L-system fractals. Elsevier, 2007.
- [62] H. Sagan, Space-Filling Curves. Springer New York, 1994. [41](#)
- [63] W. C. Gibson, The method of moments in electromagnetics. Chapman & Hall/CRC, 2008. [41](#)
- [64] R. F. Harrington and IEEE Antennas and Propagation Society., Field computation by moment methods. IEEE Press, 1993. [41](#)
- [65] Y. Li, S.-M. Yu, Y.-T. Kuo, and Y.-L. Lie, “Simulation-based evolutionary method in antenna design optimization for wlan and wireless communication applications,” in COMPUTATIONAL METHODS IN SCIENCE AND ENGINEERING VOL 1: THEORY AND COMPUTATION: OLD PROBLEMS AND NEW CHALLENGES (G. Maroulis and T. Simos, eds.), vol. 963 of AIP Conference Proceedings, pp. 659+, European Soc Computat Methods Sci & Engn; Minist Natl Educ & Religious Affairs; E4 Comp Engn, 2007. International Conference on Computational Methods in Science and Engineering, Corfu, GREECE, SEP 25-30, 2007. [41](#)
- [66] A. Zeghdoud, M. C. Derbal, and M. Nedil, “Optimization of a dual-band microstrip antenna array using genetic algorithms,” in 2018 IEEE ANTENNAS AND PROPAGATION SOCIETY INTERNATIONAL SYMPOSIUM ON ANTENNAS AND PROPAGATION & USNC/URSI NATIONAL RADIO SCIENCE MEETING, IEEE Antennas and Propagation Society International Symposium, pp. 1005–1006, Inst Elect & Elect Engineers Antennas & Propagat Soc; USNC; URSI; Inst Elect & Elect Engineers, 2018. IEEE-Antennas-and-Propagation-Society International Symposium on Antennas and Propagation / USNC/URSI National Radio Science Meeting, Boston, MA, JUL 08-13, 2018. [41](#)
- [67] F. Zaman, H. U. Hassan, S. U. Khan, A. U. Rehman, M. A. Z. Raja, and S. A. Niazi, “Backtracking Search Optimization Paradigm for Pattern Correction of Faulty Antenna Array in Wireless Mobile Communications,” Wireless Communications and Mobile Computing, vol. 2019, 2019. [41](#)
- [68] L. Wakrim, A. El Yassini, A. Khabba, S. Ibnyaich, and M. M. Hassani, “Novel design of a triple band pifa antenna by using a binary genetic algorithm,” JOURNAL OF COMPUTATIONAL ELECTRONICS, vol. 20, pp. 1373–1386, JUN 2021. [41](#)
- [69] W. Liu, “Design of a cpw-fed notched planar monopole antenna for multiband operations using a genetic algorithm,” IEE PROCEEDINGS-MICROWAVES ANTENNAS AND PROPAGATION, vol. 152, pp. 273–277, AUG 2005. [41](#)

- [70] J. Johnson and Y. Rahmat-Samii, “Genetic algorithms and method of moments (ga/mom) for the design of integrated antennas,” IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION, vol. 47, pp. 1606–1614, OCT 1999. [41](#)
- [71] G. Kaur, M. Rattan, and C. Jain, “Optimization of swastika slotted fractal antenna using genetic algorithm and bat algorithm for s-band utilities,” WIRELESS PERSONAL COMMUNICATIONS, vol. 97, pp. 95–107, NOV 2017. [41](#)
- [72] K. Fertas, S. Tebache, F. Ghanem, S. Tedjini, and R. Aksas, “Non-conventional multiband patch antenna design with filtering aspect based on genetic algorithm,” IETE JOURNAL OF RESEARCH, vol. 66, pp. 815–822, NOV 1 2020. [41](#)
- [73] S. C. Wang, Y. J. Mao, M. J. Li, H. K. Yang, and M. S. Tong, “A novel design of multiband antenna based on non-dominated sorting genetic algorithm,” in 2019 IEEE INTERNATIONAL SYMPOSIUM ON ANTENNAS AND PROPAGATION AND USNC-URSI RADIO SCIENCE MEETING, IEEE Antennas and Propagation Society International Symposium, pp. 1129–1130, Inst Elect & Elect Engineers; IEEE Antennas & Propagat Soc; Int Union Radio Sci, U S Natl Comm, 2019. USNC-URSI Radio Science Meeting / IEEE International Symposium on Antennas and Propagation (AP-S), Atlanta, GA, JUL 07-12, 2019. [42](#)
- [74] T. Yamamoto, K. Fujimori, M. Sanagi, S. Nogi, and T. Tsukagoshi, “Efficient antenna miniaturization technique by cut off of chromosome-length in genetic algorithm,” in APMC: 2009 ASIA PACIFIC MICROWAVE CONFERENCE, VOLS 1-5, pp. 1837+, 2009. Asia Pacific Microwave Conference 2009, Singapore, SINGAPORE, DEC 07-10, 2009. [42](#)
- [75] P. Werner and D. Werner, “Design synthesis of miniature multiband monopole antennas with application to ground-based and vehicular communication systems,” IEEE ANTENNAS AND WIRELESS PROPAGATION LETTERS, vol. 4, pp. 104–106, 2005. [42](#)