

Universidad de Granada
Programa de Doctorado en Tecnologías de la Información y la
Comunicación



*Modelos Empíricos de Radio Propagación en
Presencia de Vegetación para Aplicaciones Agrícolas*

Tesis doctoral

Autor: D.^a Dora Cama Pinto

Directores: Dr. D. Miguel Damas Hermoso

Dr. D. Juan Antonio Holgado Terriza

Granada, Octubre 2022

Editor: Universidad de Granada. Tesis Doctorales
Autor: Dora Cama Pinto
ISBN: 978-84-1117-659-0
URI: <https://hdl.handle.net/10481/79661>

Dora Cama Pinto

Modelos Empíricos de Radio Propagación en Presencia de Vegetación para Aplicaciones Agrícolas

Para obtener el grado de doctor como parte del programa de doctorado en Tecnologías de la Información y la Comunicación - Octubre 2022

Departamentos: Arquitectura y Tecnología de Computadores, Lenguajes y Sistemas Informáticos

Directores: Miguel Damas Hermoso y Juan Antonio Holgado Terriza

Universidad de Granada

Cuesta del Hospicio s/n

18071 Granada, España

Dedicatoria

A mi Universidad Nacional Mayor de San Marcos, Decana de América.

Fundada el 12 de mayo de 1551 en Lima - Perú por

Carlos I de España y V del Sacro Imperio Romano Germánico.

Agradecimientos

Reconocimiento especial a mis altruistas directores quienes siempre me brindaron apoyo cada vez que lo solicité: Dr. Miguel Damas Hermoso, por acompañarme durante todo el proceso con sus indicaciones precisas y compartición de conocimientos, al Dr. Juan Antonio Holgado Terriza, por su significativo apoyo incondicional en todo momento que necesité de sus acertadas sugerencias inspiradoras y enriquecedoras. Al Dr. Francisco Gómez Mula por enseñarme con su mística y apostolado que todo camino se inicia al andar.

Resumen

La producción de alimentos cultivados en invernaderos debe incrementarse, apoyándose en la agricultura de precisión (AP), para satisfacer la demanda alimentaria y comercial, teniendo en cuenta además la situación actual como consecuencia del cambio climático y los conflictos bélicos que están afectando significativamente a la producción a nivel mundial. En ese sentido, la red de sensores inalámbricos (WSN) demuestra ser una herramienta para proporcionar a los agricultores información útil sobre el estado de sus plantaciones debido a la implementación práctica sobre el terreno. Sin embargo, para medir la factibilidad de enlaces inalámbricos en el despliegue dentro del cultivo, es necesario conocer la cobertura de comunicación de los nodos que componen la red.

La propagación multitrayecto de las ondas de radio entre los transceptores de nodos de la WSN en el interior de un invernadero se ve degradada y atenuada por el intrincado complejo de tallos, ramas, hojas y frutos, todos ellos orientados aleatoriamente, bloqueando la línea de visión, y generando en consecuencia pérdida de potencia de la señal a medida que aumenta la distancia. Aunque los modelos existentes en la bibliografía, como COST235 (European Cooperation in Science and Technology - COST), ITU-R (International Telecommunications Union-Radiocommunication Sector), FITU-R (Fitted ITU-R), y Weisberger proporcionan explicación de la propagación de ondas de radio en presencia de vegetación, se encontraron diferencias significativas cuando se aplican a pruebas de campo con invernaderos de tomate. Este trabajo propone dos métodos novedosos para determinar un modelo empírico de atenuación de ondas de radio en el interior de un campo de cultivo. Incluyen como parámetro la altura de la vegetación además de la distancia entre los transceptores de los nodos WSN. El primer modelo empírico de atenuación se obtuvo aplicando regresiones regularizadas con una ecuación multiparamétrica utilizando mediciones experimentales de la intensidad de la señal recibida (RSSI) registrada por nuestro propio sistema de medición de RSSI durante las pruebas de campo realizadas en cuatro plantaciones. Los parámetros de evaluación dieron 0,948 para R^2 y su error generalizado es de 0,906. El segundo método es a través de aprendizaje profundo (Deep Learning). En este caso su rendimiento por validación cruzada R^2 es igual a 0,966 y su error generalizado es de 0,920 verificando la fiabilidad de ambos modelos empíricos.

Índice general

Resumen	11
1 Introducción	19
1.1 Introducción	19
1.2 Contexto y motivación	20
1.3 Objetivos de la Investigación	25
1.4 Estructura de la memoria	25
2 Estado del Arte	27
2.1 Redes inalámbricas de sensores en la agricultura	27
2.2 La agricultura de Precisión (AP)	30
2.3 Modelos de propagación	31
2.3.1 Indicador del RSSI	31
2.3.2 EIRP (Potencia isotrópica radiada equivalente)	32
2.3.3 Modelos de Propagación con visión de línea directa	33
2.3.4 Propagación con NLOS	37
2.4 Atenuación en presencia de vegetación	38
2.5 La Inteligencia Artificial y Deep Learning	42
3 Fundamento Teórico	45
3.1 Antecedentes	45
3.2 Método de determinación ... mediante regresión regularizada	46
3.3 Método de determinación ... mediante aprendizaje profundo	52
3.4 Evaluación de los modelos	55

4	Análisis experimental	59
4.1	Sistema de medición de atenuación de ondas de radio	59
4.1.1	Arquitectura del sistema desarrollado	61
4.1.2	Hardware del sistema	61
4.1.3	Software del sistema	62
4.2	Procedimiento de medición y pruebas de campo en 2018	63
4.3	Pruebas de campo del año 2020	67
4.4	Conjunto de datos de atenuación de ondas de radio	72
5	Determinación del modelo empírico de atenuación	75
5.1	Modelo empírico usando método de Regresión Regularizada	75
5.2	Modelo empírico usando Deep Learning	81
6	Validación del modelo teórico de atenuación	83
6.1	Datos del año 2018	83
6.2	Regresión Regularizada datos 2020 y 2018	91
6.3	Uso de Deep Learning en datos de pruebas de campo del 2020 y 2018	92
7	Conclusiones y trabajo futuro	95
7.1	Conclusiones	95
7.2	Publicaciones derivadas	96
7.3	Trabajo futuro	96

Índice de tablas

3.1 Criterios de evaluación de modelos	58
4.1 Conjunto de datos recolectado con sistema RSSI	73
5.1 Valores de parámetros optimizados (20)	78
5.2 Parámetros de evaluación de la optimización regularizada	78
5.3 Valores de parámetros optimizados (15)	80
5.4 Evaluación de parámetros en optimización regularizada	80
5.5 Comparación entre evaluación de parámetros en optimizaciones	80
5.6 Evaluación de la calidad estadística del modelo de aprendizaje profundo pro- puesto.	81
6.1 Atenuación total de la propagación a 0,5 m del suelo	85
6.2 Atenuación total de la propagación a 1,5 m del suelo	85
6.3 Porcentaje de error en la banda de 2,4 GHz a 0,5 m del suelo	90
6.4 Porcentaje de error en la banda de 2,4 GHz a 1,5 m del suelo	90
6.5 Parámetros de evaluación para mediciones de otros invernaderos	91
6.6 Evaluación de la calidad estadística del modelo de aprendizaje profundo	92

Índice de figuras

1.1	Desarrollo de revoluciones industriales y agrícolas	21
2.1	Esquema de los subsistemas en cada nodo	29
2.2	Relación de ganancia dBi respecto a un radiador isotrópico	33
2.3	Transmisión de potencia entre dos antenas	34
2.4	Posibles mecanismos de propagación en presencia de vegetación	39
3.1	Curva- L	48
3.2	λ_{optimo} en la regularización de Tikhonov	51
3.3	Esquema del modelo de aprendizaje profundo	52
3.4	Representación de la distancia y la altura	53
3.5	Valores de validación cruzada del RMSE para establecer el número de perceptrones	55
3.6	Validación cruzada del RMSE, el valor óptimo de λ	56
4.1	Nodos WSN al interior de invernadero	60
4.2	Despliegue de las dos estaciones T_x y R_x	62
4.3	Vista interior de invernadero de tomates en Almería	64
4.4	Pasos para realizar el estudio de atenuación radioeléctrica	65
4.5	Marco de plantación con nodos dentro de invernadero	66
4.6	Media del nivel de la señal recibida en dBm	68
4.7	Disposición del enlace inalámbrico entre nodos T_x y R_x	69
4.8	Promedio del nivel de la señal recibida en dBm	70
4.9	Media de atenuación en cuatro invernaderos	71
4.10	Media de atenuación frente a modelos empíricos	71
4.11	Ubicación del invernadero	72

5.1	Valores PIP para el modelo elegido	76
5.2	RMSECV en función del número de parámetros	76
5.3	Solución obtenida para el conjunto de 20 parámetros	77
5.4	Solución obtenida para el conjunto de 15 parámetros	79
5.5	Solución obtenida para el modelo de aprendizaje profundo	82
6.1	Nivel de señal en dBm y cobertura máxima	84
6.2	Pérdida de trayectoria a 0,5 m y 1,5 m del suelo	85
6.3	Comparación de modelos con medición de campo a 50 cm del suelo	87
6.4	Comparación de modelos con medición de campo a 150 cm del suelo	88
6.5	Medición de campo con modelos optimizados	89
6.6	Curvas del modelo propuesto	92

Capítulo 1

Introducción

1.1. Introducción

Las redes inalámbricas de sensores (WSN, Wireless Sensor network en inglés) constituyen una tecnología clave en el concepto de Internet de las cosas (IoT). Dichas redes están formadas por un conjunto de nodos sensores que recogen información y la envían a otros nodos sumideros, también llamados estaciones base (BS) (Aishwarya Lakshmi et al., 2019; Liu, 2012; Vutukuri et al., 2014). Los nodos contienen sensores de bajo consumo energético y baja potencia para prolongar la vida útil de sus baterías, siendo en algunos casos auto-sostenibles a través del proceso de aprovechamiento energético a través de paneles solares (Edwards-Murphy et al., 2016; Santoshkumar y Udaykumar R.Y, 2015). La Revista Tecnológica del MIT calificó las WSN como una de las diez tecnologías emergentes que cambiarán el mundo, mientras que la revista "Business Week" la catalogó como una de las 21 tecnologías más importantes para el siglo XXI, porque si consideramos que Internet conecta seres humanos a través de ordenadores, la WSN facilita la conexión con el mundo físico (Zhou et al., 2014). Al comunicar el mundo digital con el real (Caicedo-Ortiz et al., 2018; Suman et al., 2018), las WSN se convierten en parte integral de la IoT pudiéndose utilizar para aplicaciones de bajo coste en entornos exteriores (Cama-Pinto et al., 2020; Zapata-Sierra et al., 2019) para monitorizar una gran variedad de parámetros ambientales en la Agricultura de Precisión (Hamasaki, 2019; Onofre et al., 2021) como la temperatura, humedad, nutrientes del suelo, etc. desplegados en entornos de vegetación (Foerster et al., 2015; Picallo et al., 2019). Los nodos que conforman las WSN están equipados con un microprocesador, un transceptor,

una unidad de energía limitada y uno o más sensores pequeños que recogen datos para su posterior almacenamiento y procesamiento (Sheikh-Hosseini y Samareh Hashemi, 2022) lo que permite obtener una mejor percepción y comprensión del entorno de forma similar a la humana. Gracias a los recientes avances en las comunicaciones inalámbricas y la miniaturización de la tecnología electrónica, tienen una amplia gama de aplicaciones en el campo militar (Kumar et al., 2016; Pawgasame, 2016; Roy y Nene, 2015), tráfico vehicular (Nellore y Hancke, 2016; Sumedha Sirsikar y Manoj Chandak, 2017; Yu et al., 2016), vigilancia (Jaigirdar y Islam, 2016; Kabilan y Selvi, 2016; Sert et al., 2016), rastreo de objetos (Cao et al., 2016; Chen et al., 2016; Ngo-Quynh et al., 2016; Sheltami et al., 2016), monitoreo ambiental (Antolín et al., 2016; Cheng et al., 2016; Wang et al., 2015), industria (Amutha et al., 2020; Eagle et al., 2015), salud (Agrawal, 2015; Mamta y Prakash, 2016; Preethichandra, 2015; Sharma et al., 2021) y la agricultura (del Felipe et al., 2022; Goel y Bindal, 2022; Madhumathi et al., 2022), entre otros. La WSN utiliza principalmente como protocolo de comunicación el estándar IEEE 802.15.4 que define la capa física y acceso, siendo el marco de referencia para otras capas superiores desarrolladas en IoT (Ferreira Neto et al., 2021; Khan y Herrmann, 2021; López-Vilos et al., 2021; Musaddiq et al., 2021; Sharma et al., 2021) como 6LoWPAN o ZigBee (Bruniaux et al., 2021; Park y Park, 2021; Raich y Kastner, 2021; Vivek Raj et al., 2022).

1.2. Contexto y motivación

La agricultura es un pilar fundamental en la economía y sociedad de un país, aumentando la productividad agrícola a través de tecnologías de vanguardia con el fin de contribuir al progreso económico y alimentación de sus habitantes (Rangwani et al., 2021). Debido al aumento de la población mundial, la agricultura ha experimentado avances de la mano con la industria (ver figura 1.1) para elevar su productividad. Los sistemas embebidos, la ingeniería de software y las tecnologías de la comunicación durante la era de la Industria 3.0 mejoraron la automatización. Estos desarrollos condujeron a la revolución agrícola conocida como Agricultura 3.0 (o Agricultura de Precisión, AP) cuyo objetivo era explotar tecnologías de la información para la agricultura de precisión mediante la supervisión del rendimiento, aplicaciones de tasa variable y orientación de sistemas agrícolas. La cuarta revolución industrial (Industria 4.0) se caracteriza por la fusión de tecnologías digitales emergentes como el Internet de las Cosas (IoT), robótica, big data, inteligencia artificial (AI) y blockchain. Transfiriendo autonomía e inteligencia de la industria 4.0 a la agricultura, nace la Agricul-

ra 4.0, aumentando los procesos de producción de cultivos y rentabilidad de las explotaciones (Dayioğlu y Türker, 2021; Liu et al., 2021a; Raj et al., 2021).

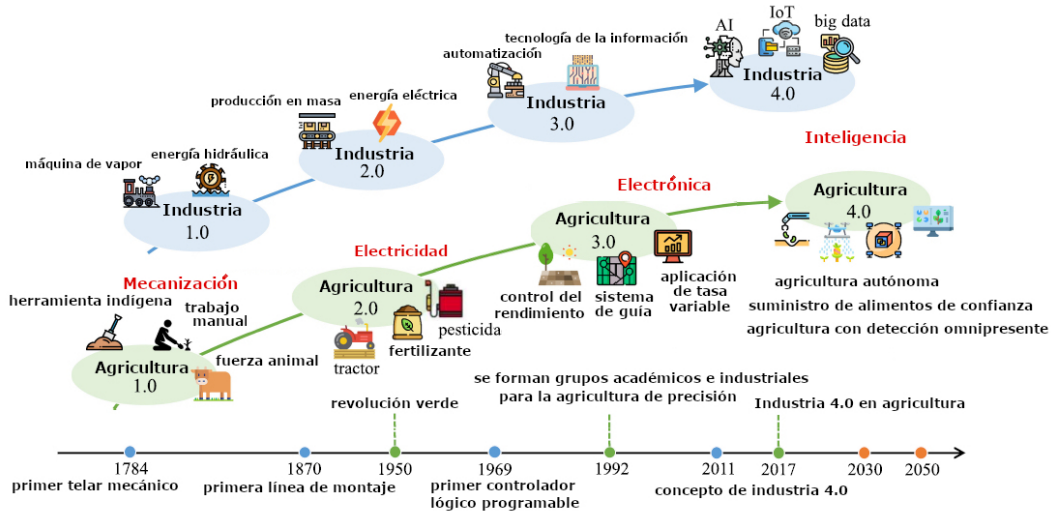


Figura 1.1: Desarrollo de revoluciones industriales y agrícolas (Dayioğlu y Türker, 2021)

La WSN tecnológicamente está complementándose de forma acelerada por el IoT (Internet of Things) e incluso por redes 5G (Cama-Pinto et al., 2021a; Mentsiev y Gatina, 2021). Esto permite gestionar la variabilidad espacial y temporal en la agricultura mediante el uso de tecnologías de información y control con los que se recogen datos con una mayor resolución que los obtenidos directamente por teledetección, ensayos de laboratorio, etc. (Srisooksai et al., 2018). Ese conocimiento pueden ayudar a comprender por ejemplo los cambios que se producen durante los ciclos de siembra.

El uso de la WSN surge de la necesidad de utilizar tecnologías que faciliten la recolección de información sobre las condiciones del suelo y medio ambiente en zonas agrícolas, consiguiendo que las prácticas agrícolas sean supervisadas, evaluadas y controladas. Los datos influyen directamente en la toma de decisiones sobre las actividades a realizar en toda la plantación. La AP produce más alimentos con recursos limitados como agua y suelo (Peng et al., 2019) aumentando de forma efectiva la calidad y rendimiento de las cosechas (Miao et al., 2021).

El interés de la WSN en el campo agrícola ha aumentado con la AP y con las aplicaciones de grandes datos en la agricultura. Dichas aplicaciones de WSN apoyando a la AP cumplen la función de supervisar y controlar la gestión del campo reduciendo los costes de monitorización y gestión de producción de cultivos, más aún a nivel de cada planta en lugar de monitorizar genéricamente toda el área de un invernadero. También proporcionan en tiempo

real información a los agricultores sobre las tierras de cultivo ayudando a tomar decisiones e implementar prácticas en el campo de manera oportuna y correcta (Khairunni et al., 2018; Wahaishi y Aburukba, 2022). El despliegue de las WSN para la AP proporciona un mayor rendimiento económico al optimizar la calidad del producto con la cantidad de la cosecha, lo que permite minimizar los costes (Piñeres-Espitia et al., 2017; Sabri et al., 2013; Sanjeevi et al., 2020; Zervopoulos et al., 2020). Por ello, en la presente investigación, realizando pruebas de campo dentro de invernaderos de producción de tomate, nos centramos en estudiar y comparar el fenómeno de propagación y atenuación de ondas de radio de los nodos inalámbricos a distintas alturas y distancias en la banda sin licencia en su uso de 2,4 GHz, destinada a la industria y al campo científico y médico (ICM). Dicha banda también es la más utilizada en el mundo de la agricultura de precisión (Tzounis et al., 2017) y en particular en el interior de invernaderos.

El rol de las redes de sensores inalámbricos (WSN) es primordial dentro del concepto de la IoT (Sorri et al., 2022; Vanitha et al., 2021) porque la supervisión o monitorización de un entorno depende fundamentalmente de la capacidad perceptiva del sistema y, para ello, los nodos sensores inalámbricos deben poder transmitir datos desde cualquier ubicación siempre que haya una conexión de red inalámbrica (Abdollahi et al., 2021; Suresh et al., 2014). A través de la información de los nodos sensores se registran datos de variables en campos de cultivo transfiriéndolos inalámbricamente a la estación base para la supervisión y toma de decisión y supervisión (Mahajan y Badarla, 2021b). Así, por ejemplo, la medición y registro en tiempo real de la humedad del suelo en grandes áreas agrícolas a través de la WSN (Parlato et al., 2020) permite mitigar la escasez de agua, ahorrando y siendo más eficientes en el riego agrícola que consume aproximadamente el 70 % del agua dulce total del mundo (Peng et al., 2019; Xuanrong et al., 2018). La eficiencia y el rendimiento obtenido ayuda de este modo a contrarrestar los efectos negativos del cambio climático, la reducción de la superficie terrestre destinada a la agricultura y la disminución del agua dulce, entre otros (Brinkhoff y Hornbuckle, 2017; Montoya, Gomez, Manzano-Agugliaro, Cama-Pinto, García-Cruz, y Cruz, 2013).

Según la Organización de las Naciones Unidas para Agricultura y Alimentación (FAO), el aumento de producción agrícola proporcionará elementos esenciales al ser humano (Khairunni et al., 2018), alimentando la creciente población de la Tierra al producir 70 % más de alimentos en 2050 que el 2006. Prevé además que la población mundial alcanzará 8000 millones de personas en 2025. El incremento en demanda de cultivos y producción alimenta-

ria está asociado con el crecimiento de la población mundial, siendo actualmente conforme a datos de la FAO (Food and Agriculture Organization) de las Naciones Unidas 7700 millones de humanos, proyectados a 9400 millones en el 2030 y 10 100 millones en el 2050, año que la población mundial necesitará un 70 % más de alimentos que en el 2006 (Razafimandimby et al., 2017), 42 % más de tierras de cultivo y esperando tener los cultivos en ecosistemas sanos con la gestión sostenible de la tierra y de 120 % más de agua para fines relacionados a la alimentación Akhigbe et al. (2021); Bartkowiak (2021); Mahbub (2020); Saeed et al. (2019); Sagheer et al. (2021).

En este contexto, las llanuras de la provincia de Almería representan uno de los mayores potenciales para el uso de AP en España, razón por la que en esta localidad se realizaron las pruebas de campo durante la investigación. Está situada en el sureste de la Península Ibérica y cuenta con la mayor concentración de invernaderos de la cuenca mediterránea (31 000 ha) y del mundo, visualizándose desde el espacio (Castillo-Díaz et al., 2021; Luis Caparrós-Martínez et al., 2020; Massa et al., 2020; Pinna-Hernández et al., 2020). El 80 % de la agricultura intensiva de frutas y hortalizas en sus invernaderos contribuyen a que Almería haya convertido a España en el tercer exportador de estos productos en el mundo después de China y EE.UU, siendo primero en la Unión Europea (UE). Factura anualmente casi 2000 millones de euros por los tres millones de toneladas de hortalizas y fruta que representan el 0,6 % de la producción agrícola total de la UE, con productividad 30 veces superior a la media europea (Aznar-Sánchez et al., 2020; Camacho-Arévalo et al., 2021; Duque-Acevedo et al., 2020; Martin-Gorriz et al., 2021). Así mismo, la provincia de Almería es la primera productora de tomate en España con 996 254 toneladas en el año 2018 (Honoré et al., 2019; Manríquez-Altamirano et al., 2020; Téllez et al., 2020), aportando la 70 % de tomates para consumo fresco de la comunidad autónoma de Andalucía y el 50 % a escala nacional, colocando a España como primer productor de la UE con una cuota del 30 % del total, siendo sus principales competidores: Alemania, Francia y Polonia (Martínez-Valderrama et al., 2020). Cabe resaltar que el tomate es un nutraceutico que cuenta con la mayor fuente de licopeno (principal carotenoide que se encuentra predominantemente en su cáscara) con beneficioso efecto para la salud humana por su antioxidante, cardioprotector, antihipercolesterolemizante, antidiabético, antimicrobiano, fotoprotector y anticancerígeno (Carvalho et al., 2021), especialmente contra el cáncer de próstata (Sosalagere et al., 2022).

Los invernaderos que producen tomate y cualquier otro tipo de cosecha y emplean WSN en la AP deben lidiar con la propagación multitrayecto de ondas de radio entre transceptores

de los nodos inalámbricos. La señal degradada y atenuada aleatoriamente por obstáculos de vegetación bloquean la línea de visión (LOS) generando pérdida de potencia a medida que aumenta la distancia. La atenuación de la señal de radio es inevitable debido a pérdida de trayectoria del espacio libre, afectada además por la reflexión, refracción, difracción y absorción de la señal durante la propagación de onda. Los efectos de la vegetación en propagación de radiofrecuencia (RF) se han investigado ampliamente en el campo de las telecomunicaciones, pero no tan extensamente para redes ad hoc de la WSN. La atenuación debido a pérdida por vegetación se ha demostrado para frecuencias entre 30 MHz y 60 GHz, y evidencian un desvanecimiento más pronunciado en frecuencias superiores a 1 GHz, ya que las longitudes de onda se hacen más pequeñas que algunas estructuras de las plantas. Por ejemplo, dependiendo de la altura de la copa de la planta y orientación de la antena receptora, hay potencialmente varias rutas en la transmisión de las señales, incluyendo reflexión del suelo, propagación de onda superficial sobre la parte superior de las copas de las plantas y dispersión/difracción al rededor de las hojas, ramas y troncos. Modelar esta pérdida en la trayectoria resulta difícil debido a la diversidad de posibilidades en la arquitectura de la vegetación, siendo la estructura de los bosques particularmente compleja por sus variables de densidades foliares y leñosas unidas a las distribuciones heterogéneas de estratos forestales verticales y horizontales (Rankine et al., 2014). Por ello, para establecer la adecuada y eficiente disposición de nodos que conforman una WSN en el interior de un campo de cultivo, es necesario conocer la pérdida de trayectoria de señales inalámbricas entre nodos (presupuesto de enlace) con objeto de planificar mejor su diseño.

Ante esta perspectiva y potencial utilidad de las WSN en la AP, se hicieron pruebas de campo durante el mes de febrero de los años 2018 y 2020 con nodos sensores distribuidos en invernaderos de tomates de Almería (Andalucía – España) analizando las pérdidas de trayectoria de ondas de radio producidas por la vegetación. Los valores obtenidos en las pruebas de campo se han comparado con modelos empíricos, como el Weissberger e ITU-R entre otros (Cama-Pinto et al., 2019), encontrándose considerable disparidad de valores porque, en general, estos modelos sólo tienen en cuenta distancia y frecuencia entre los transceptores de nodos WSN. Por ende, esta investigación presenta un nuevo modelo empírico cuyas predicciones, validadas en invernaderos de tomate, mejoran a sus predecesores.

1.3. Objetivos de la Investigación

El objetivo general de la investigación es desarrollar nuevos métodos que nos permita generar modelos empíricos de propagación de ondas de radio en presencia de vegetación, teniendo presente la distancia entre nodos y la altura de la antena de los nodos respecto al suelo.

Para obtener el objetivo general se necesita cumplir con los siguientes objetivos específicos:

1. Desarrollar un nuevo sistema de medida RSSI para la realización de mediciones experimentales de atenuación de señal en el interior de invernaderos.
2. Realizar pruebas de campos de mediciones de RSSI en diferentes invernaderos con el sistema desarrollado y registrarlo para obtener un dataset.
3. Estudiar y analizar los modelos analíticos y empíricos propuestos en la bibliografía para la medición de la atenuación de la señal y comprobar su validez con las pruebas de campo realizadas.
4. Explorar y desarrollar métodos para la determinación de nuevos modelos empíricos de atenuación de ondas con línea de vista obstruida por presencia de cultivos en invernaderos usando la banda de 2,4 GHz que incluya otros parámetros como la altura de la vegetación además de la distancia entre el nodo transmisor y el receptor. Se tendrán en cuenta tanto métodos basados en regresión como basados en machine learning.
5. Validar los modelos empíricos obtenidos con los datos experimentales de las plantaciones para ver si se ajustan correctamente.

1.4. Estructura de la memoria

El capítulo 2 analiza el estado del arte y trabajos relacionados con la investigación. El capítulo 3, presenta el método utilizado respecto al Estado del Arte en la determinación del modelo teórico de atenuación basado en regresión regularizada y Deep Learning. El capítulo 4 explica el análisis experimental utilizado. El capítulo 5 indica cómo es aplicado el método descrito en la sección anterior. El capítulo 6 valida y describe los modelos obtenidos con datos procedentes del estudio del año 2020 contrastándolo con datos del 2018. Finalmente, en el último capítulo, se presentan las conclusiones y las publicaciones derivadas de la investigación así como los posibles trabajos futuros.

Capítulo 2

Estado del Arte

En este capítulo se describen y revisan los principales conceptos que se han utilizado a lo largo de la investigación. Se detallan los aspectos claves en la determinación de los modelos de propagación utilizados para explicar la atenuación de la señal en campos de cultivo como los invernaderos, así como los principales modelos que se han propuesto hasta ahora en la bibliografía.

2.1. Redes inalámbricas de sensores en la agricultura

Las redes inalámbricas de sensores (Wireless Sensor Network en inglés, WSN) se basan en nodos de baja tasa de transmisión de datos y baja potencia, interconectados entre ellos por sus módulos de radio para transportar la información de sus sensores registrados hasta un nodo en específico denominado nodo sumidero. Presentan ventajas en comparación a las redes cableadas porque son más económicas y fáciles de desplegar (Ghorbel et al., 2021), y sus enormes perspectivas de aplicación atraen la atención del mundo académico e industrial (Liu et al., 2021a). Posibilitan desplegar infraestructuras de comunicación y detección en zonas donde, de otro modo, sería poco práctico o imposible hacerlo (Haber et al., 2013). Por ejemplo, en un escenario agrícola es posible aplicarlos para monitorizar entornos amplios gracias a su estructura escalable capaz de gestionar muchos nodos al mismo tiempo (Leccisi et al., 2021) superando dificultades de despliegue, altos costes de instalación y mantenimiento (Chaiwatpongsakorn et al., 2014). Los nodos de una WSN pueden intercomunicarse rápidamente de forma automática, utilizando protocolos de comunicación de red jerárquicos

y algoritmos distribuidos. Por otra parte, dado que los nodos sensores son de reducido tamaño y tienen buena capacidad de cooperación, su despliegue tiene pequeño impacto en el entorno agrícola donde está desplegado. Además, presentan otras ventajas, como bajo consumo de energía, capacidad de auto organización y procesamiento local, constituyendo una plataforma prometedora para la implementación de sistemas de monitorización cada vez más utilizados en la agricultura (Galvan-Tejada y Duarte-Reynoso, 2012; Galvan-Tejada et al., 2013; Guo et al., 2015; Queiroz et al., 2017; Stewart et al., 2017; Zhang y Li, 2016).

La WSN de nuestro estudio se basa en el estándar IEEE 802.15.4. Opera en la banda de 2,4 GHz con menor longitud del radio de la sección transversal de cada zona de Fresnel y mayor velocidad de transmisión en comparación a las bandas de 868 y 915 MHz (Yoshimura et al., 2016). Es una herramienta importante para la vigilancia del medio ambiente (Li et al., 2013; Zervopoulos et al., 2020), y su uso en zonas rurales con presencia de vegetación está creciendo exponencialmente (Gay-Fernandez y Cuinas, 2014; Li et al., 2013). Sin embargo, cada sensor utilizado en la WSN tiene un alcance limitado (de Sales Bezerra et al., 2015) debido a la obstrucción de las ondas de radio cuando atraviesan la vegetación. Por tanto, es crucial conocer la posición, nivel de potencia de transmisión y propagación de la señal de radio en el entorno del despliegue, planificándolo con antelación y desplegando eficazmente la WSN en presencia de vegetación (Rao et al., 2016). La atenuación de la señal propagada aumenta con la distancia (Zhang et al., 2010) y en zonas de vegetación densa, como huertos y bosques, donde la línea de visión (LOS) entre nodos suele ser inexistente, el follaje de los árboles causa atenuación adicional (Anastassiou et al., 2014) por difracción, reflexión y dispersión sin línea de visión (NLOS) (Zuniga y Krishnamachari, 2004), especialmente debido a presencia de agua dentro de hojas y tallos (Ngandu et al., 2013).

En un escenario de AP, la WSN sirve como sistema de monitorización local de cultivos que permite tomar decisiones adecuadas en un sistema de producción controlado y afectado por el cambio climático (Salim y Mitton, 2021; Wu et al., 2016a). Los valores de los sensores en campos agrícolas se ajustan y fijan de acuerdo con los requisitos específicos de cada tipo de planta como, por ejemplo, un rango apropiado para proporcionar información continua sobre condiciones de variables del campo en temperatura, viento, luz, humedad del suelo, nutrientes e iluminancia (Hsiao y Sung, 2021; Xuanrong et al., 2018).

La WSN es un sistema distribuido compuesto por dispositivos embebidos (Zhang y Li, 2016) llamados nodos o motas, comunicándose de forma inalámbrica en una red. Cada nodo cuenta

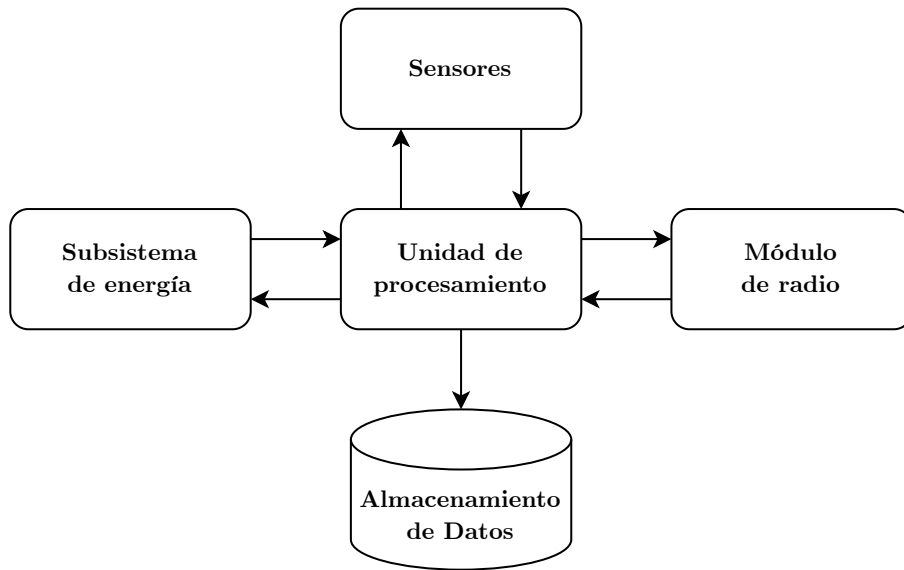


Figura 2.1: Esquema de los subsistemas en cada nodo

con cuatro subsistemas descritos en la figura 2.1, además de un sistema de almacenamiento de datos. El primero, detecta el entorno mediante sensores que miden datos físicos y los traducen en señales analógicas, transformándose posteriormente en señales digitales a través del ADC (convertidor analógico - digital). El segundo, subsistema de procesamiento, contiene el microcontrolador que realiza cálculos sobre datos digitales. El tercero es el subsistema de comunicación encargado de intercambiar información entre diferentes nodos sensores mediante sus transceptores (Mentsiev y Gatina, 2021). Los módulos de radio operan según el estándar IEEE 802.15.4, utilizando con regularidad transceptores de radiofrecuencia en la banda de 2,4 GHz (2400-2483,5 MHz) (Azmi et al., 2021) al estar disponible libremente en todo el mundo y al ser la más utilizada entre los módulos de radio de los fabricantes que utilizan IEEE 802.15.4. Por último, el cuarto subsistema es de alimentación, con diseño basado en ahorro de energía, dado que los sensores operan con presupuesto energético extremadamente limitado (Razafimandimby et al., 2017; Ritika et al., 2020).

A través de la transmisión inalámbrica de datos, la WSN sustenta la recopilación de información sobre un amplio espectro de parámetros físicos en agricultura gracias a su auto-organización, bajo coste, bajo consumo de energía, amplia área de cobertura y despliegue en entornos complejos y cambiantes sobre áreas con suministro de energía problemático entre otras características (Montoya et al., 2013), facilitando que prácticas agrícolas sean más productivas, sostenibles y respetuosas con el medio ambiente (Maiolo y Polese, 2021; Saiz-Rubio y Rovira-Más, 2020; Sathish y Srinivasan, 2021).

Debido a que la agricultura tradicional al aire libre no satisface la producción de alimentos, unido a la reducción de tierras agrícolas destinadas a la construcción de obras civiles, una solución óptima son los cultivos protegidos o invernaderos que elevan el número de cosechas, y mejor aún, transformados a invernaderos inteligentes utilizando las tecnologías de la información y la comunicación, contribuyen al aumento de la producción agrícola (Andrianto et al., 2020). La computación en la nube y el Internet de las cosas (IoT) hacen inteligente los sistemas tradicionales (Gómez et al., 2012; Latino et al., 2022; Ullah et al., 2021). Así, la agricultura inteligente (SF, Smart Farming, en inglés) es ejemplo de este proceso mejorando la productividad y reduciendo el excedente de insumos en los cultivos (Pflanzner et al., 2020).

2.2. La agricultura de Precisión (AP)

Los métodos agrícolas tradicionales son insuficientes para satisfacer la demanda alimentaria siendo necesaria la AP que reúne técnicas y tecnologías de precisión utilizadas individualmente o en combinación para controlar la variabilidad del campo. El concepto de AP surge en 1980 por parte de Sott et al (Sott et al., 2021) para identificar aquellos aspectos que pueden mejorar el rendimiento de las actividades agrícolas como por ejemplo introducir la gestión automatizada de datos (Mazzetto et al., 2020). Utiliza eficazmente productos químicos y reduce la aplicación de insumos, costes de producción y contaminación ambiental (Krishnan y Kumar, 2019; Mancipe-Castro y Gutiérrez-Carvajal, 2022; Nasiri et al., 2022) en el momento y lugar adecuados durante el crecimiento de la plantación y su explotación, consiguiendo menor variabilidad en los resultados de la observación, medición y respuesta inter e intra de los cultivos (França et al., 2020; Tendulkar, 2020). La AP produce más alimentos con recursos limitados como agua y suelo (Peng et al., 2019) aumentando de forma efectiva la calidad y rendimiento de las cosechas (Miao et al., 2021). Algunas de las tecnologías de la AP son el posicionamiento global (GPS), sistemas de información geográfica (GIS), seguimiento y cartografía de rendimientos (Bauerdick et al., 2020; Shcherbakov y Baramykov, 2022).

Teniendo como base los paradigmas de la industria 4.0 (Cuarta revolución industrial), la AP (Tercera Revolución Agrícola) evolucionó a la Agricultura 4.0 (A4.0) denominándose también SF (França et al., 2020) al integrar las tecnologías de la información y la comunicación (TIC) en las prácticas agrícolas tradicionales para supervisar una amplia gama de parámetros agrícolas que mejoran el rendimiento de los cultivos (Boursianis et al., 2022). Ambos términos (SF and A4.0) relacionados con la agricultura digital (DA), son el motor

de cambio en la revolución basado en la sostenibilidad, eficiencia, productividad y seguridad alimentaria. Representa el uso de las tecnologías IoT, Inteligencia Artificial, big data, computación en la nube y otros sistemas y dispositivos inteligentes afines a la gestión de cultivos y explotaciones agrícolas (Sott et al., 2021). La IoT potenciada con las WSN reciben la atención de los investigadores para aplicaciones de SF. Sus sensores agrícolas registran datos de variables en campos de cultivo transfiriéndolos inalámbricamente a la estación base para toma de decisión y supervisión (Mahajan y Badarla, 2021b). La agricultura inteligente permite a los agricultores y ganaderos gestionar sus cultivos, adecuando el uso de la tierra a sus necesidades, minimizando costes y recursos (Krishnan y Kumar, 2019).

2.3. Modelos de propagación

El camino que sigue la señal desde que sale de un nodo transmisor al nodo receptor puede ser simple y sencillo cuando hay visión directa entre los dos nodos o bien mucho más complicado cuando están expuestos a distintos tipos de obstáculos como las plantas, tallos, etc en el cultivo de un invernadero que interfieren en la señal provocando una atenuación mayor de la esperada. Los modelos de propagación tratan de predecir el comportamiento que va a tener la atenuación de la señal ante obstáculos, en nuestro caso, la vegetación. En el caso más sencillo, en el modelo de espacio libre o el modelo de “Dos-Rayos” la atenuación depende inversamente con la distancia (Anderson et al., 2013).

En esta sección se va a analizar los parámetros relevantes en la medida de la atenuación así como los modelos teóricos y empíricos de propagación que permiten determinar la atenuación en presencia de vegetación como nos encontramos en los invernaderos.

2.3.1. Indicador del RSSI

El indicador de fuerza de la señal recibida (RSSI por las siglas del inglés Received Signal Strength Indicator) revela valores de potencia en la propagación de onda de radio. El entorno, crecimiento de los cultivos, y las diferentes alturas de las antenas influyen en la medición del RSSI (Cama-Pinto et al., 2017; Huang y Chan, 2014; Wang et al., 2016). Los modelos utilizados para predecir el RSSI entre dos transceptores se denominan modelos de propagación (Rao et al., 2016).

No es posible garantizar la existencia de un camino de visión directa (LOS, Line of sight, en inglés) de la onda de radio entre los nodos de la WSN en el interior de un invernadero

debido a la distribución aleatoria de la vegetación (Mukherjee et al., 2021). No obstante, puede modelarse la señal con línea de visión directa usando el modelo de propagación en espacio libre de Friis (Friis, 1946) en las separaciones que definen el espacio entre secciones de vegetación dentro del invernadero que están libre de obstáculo y sirven de pasadizo para desplazamiento del agricultor (Nurwarsito y Aziz, 2021), mientras que, donde está presente la vegetación dentro del invernadero, la comunicación será teniendo en cuenta que no hay visión directa (NLOS, Non Line of sight) entre los transeptores (Aminah et al., 2021).

2.3.2. EIRP (Potencia isotrópica radiada equivalente)

La antena isotrópica irradiará por igual en todas direcciones la potencia suministrada a ella teniendo ganancia 0 dBi. Sin embargo, si esto sucediese, la potencia de salida de la antena transmisora no sería práctica. Solo es necesario que la antena transmisora irradie señal en la dirección que recibirá la antena receptora. De este modo concentrando la potencia en esa dirección con la ganancia de la antena, la potencia de consumo para este fin se reduce drásticamente (Bensky, 2019). Así, mientras la antena tenga mayor ganancia, mejorará la EIRP (Mao et al., 2021) aumentando el rendimiento de los transmisores (Xie et al., 2021) dentro del cumplimiento de las regulaciones de cada país. Por ejemplo, el valor admisible del EIRP en Europa es de 3,3W, mientras que en Estados Unidos 4W (Alibakhshikenari et al., 2022).

La máxima EIRP transmitida (Lee et al., 2022; Rytel-Andrianik, 2021; Xie et al., 2021) está definida por 2.1,

$$P_{EIRP} = P_{in}G \quad (2.1)$$

P_{in} : Potencia de entrada neta admisible en la antena.

G : Ganancia de radiación de la antena.

En escala logarítmica la potencia de entrada neta a la antena se restringe de nuevo (Behih et al., 2021) mediante 2.2:

$$EIRP[dBm] = P_{in}[dBm] + G[dBi] \quad (2.2)$$

La potencia de radiofrecuencia se mide en milivatios (mW) o en escala logarítmica de decibelios (dB), referenciada como 1 mW de potencia (dBm) (Fahrion, 2012).

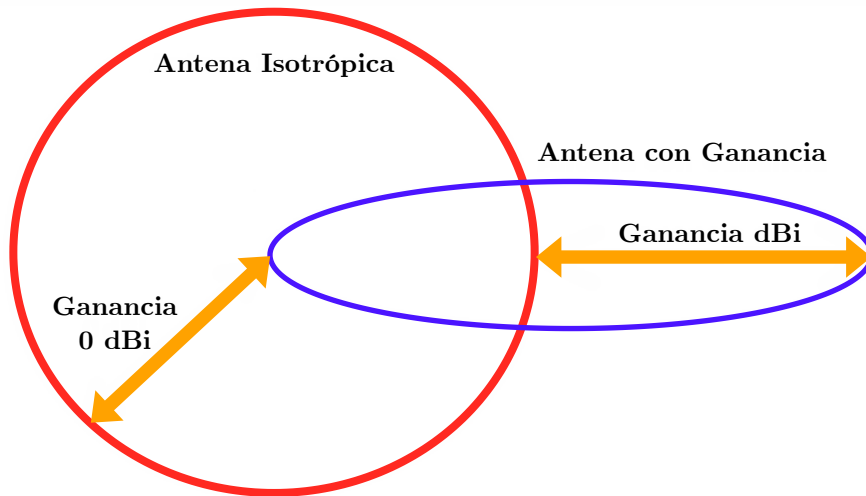


Figura 2.2: Relación de ganancia dBi respecto a un radiador isotrópico

La ganancia de la antena es la relación entre la intensidad de la señal en dirección de mayor radiación respecto a una antena isotrópica ideal. En una antena direccional, la intensidad de la señal a una distancia d es más fuerte en algunas direcciones que en otras (Farahani, 2008). Debido a ello, y porque no puede diseñarse ni construirse una antena isotrópica en las telecomunicaciones, se emplea el término dBi, reflejando el valor de ganancia en dB que tiene una antena en relación a una antena isotrópica ideal (Schantz, 2003). En la figura 2.2 observamos la relación entre ganancias de una antena direccional respecto a otra isotrópica. En aras de mantener coherencia, cualquier ganancia de antena debe citarse en relación a una antena isotrópica siendo común emplear escala en dB, citando la ganancia en dBi, con “i” indicando que utiliza antena isotrópica de referencia (Haslett, 2008). Por ejemplo, una antena direccional con ganancia de 2,5 dBi aumenta en 2,5 dB la potencia de la señal de salida en una dirección comparandola con la potencia de salida de una antena isotrópica (Farahani, 2008).

2.3.3. Modelos de Propagación con visión de línea directa

Como ya se ha indicado en secciones anteriores, se pueden distinguir entre modelos de propagación de visión directa (LOS) entre el transmisor y el receptor y los modelos de propagación sin línea de visión directa (NLOS). En esta sección se describen los de propagación de visión directa o LOS:

- Modelo de transmisión de Friis:** Relaciona potencia recibida con transmitida, de acuerdo a la figura 2.3, en términos de áreas efectivas de antena receptora y transmisora




Figura 2.3: Transmisión de potencia entre dos antenas

a través del espacio libre (ecuación 2.3) (Shaw, 2013):

$$\frac{P_{exit_{rx}}}{P_{in_{tx}}} = \frac{A_r A_t}{d^2 \lambda^2} \quad (2.3)$$

Donde:

$P_{in_{tx}}$: Potencia que es alimentada la antena transmisora en sus terminales de entrada.

$P_{exit_{rx}}$: Potencia disponible en los terminales de salida de la antena receptora.

A_t : Área efectiva de la antena transmisora

A_r : Área efectiva de la antena receptora

d : Distancia entre las antenas

λ : Longitud de onda

El área efectiva A de una antena es utilizada para recibir onda electromagnética plana de polarización lineal, sea de transmisión o de recepción (Friis, 1946). En términos de su ganancia G para una antena transmisora o receptora el área efectiva viene dada 2.4:

$$A = \frac{\lambda^2 G}{4\pi} \quad (2.4)$$

Relacionándolo con la ecuación de transmisión de Friis se transforma a la ecuación 2.5 (Barbieri et al., 2019):

$$\frac{P_{exit_{rx}}}{P_{in_{tx}}} = \frac{1}{d^2 \lambda^2} \cdot \frac{\lambda^2 G_r}{4\pi} \cdot \frac{\lambda^2 G_t}{4\pi} \quad (2.5)$$

G_t : Ganancia antena transmisora.

G_r : Ganancia antenna receptora.

Simplificando tenemos 2.6 (Kim et al., 2019; van den Biggelaar et al., 2021),

$$\frac{P_{exit_{rx}}}{P_{in_{tx}}} = \frac{\lambda^2 G_r G_t}{(4\pi d)^2} \quad (2.6)$$

De esta forma, la potencia a la salida de la antenna receptora $P_{exit_{rx}}$ está definida en 2.7 (Koley et al., 2020),

$$P_{exit_{rx}} = \frac{(P_{in_{tx}})(\lambda^2 G_r G_t)}{(4\pi d)^2} \quad (2.7)$$

Teniendo en cuenta que $\lambda = \frac{c}{f}$ donde c = Velocidad de la luz en el vacío (m/s), f = Frecuencia de transmisión (Hz) (Alalade et al., 2019). Reemplazamos longitud de onda λ en términos de c y f_c , frecuencia de la portadora modulada. En la ecuación 2.8 $P_{exit_{rx}}$ será (Kulkarni et al., 2019, 2021; Okada, 2020; Pal et al., 2019; Roy y Koley, 2021)

$$P_{exit_{rx}} = P_{in_{tx}} G_r G_t \left(\frac{c}{4\pi f_c d}\right)^2 \quad (2.8)$$

La ecuación 2.8 consta de tres componentes que afectan la potencia recibida, estas son: ganancia de las antenas, frecuencia y la distancia total. Las ganancias de las antenas actúan como multiplicador lineal para mejorar la transmisión inalámbrica. La potencia recibida disminuye cuando la frecuencia y distancia aumentan (Hao Chai et al., 2020).

En el campo de las telecomunicaciones la escala logarítmica es usada para representar y manipular un amplio rango de números de manera compacta, facilitando cálculos en sumas y restas en vez de multiplicaciones y divisiones (Esmailzadeh, 2016). Así, a partir de la ecuación 2.3 obtenemos la ecuación de transmisión de Friis en dB con LOS, relacionando potencia recibida y transmitida y ganancia de antenas (ecuación 2.9) (Ebongue et al., 2015; Khan et al., 2020; Sern et al., 2020; Thanakan et al., 2021):

$$P_{exit_{rx}}(dBm) = P_{in_{tx}}(dBm) + G_{rx}(dBi) + G_{tx}(dBi) + 20 \log\left(\frac{\lambda}{4\pi d}\right) \quad (2.9)$$

En otros términos (Marsic et al., 2021),

$$P_{exit_{rx}}(dBm) = P_{in_{tx}}(dBm) + G_{rx}(dBi) + G_{tx}(dBi) - 20 \log\left(\frac{4\pi d}{\lambda}\right) \quad (2.10)$$

La ecuación de transmisión de Friis en dB queda como indica la ecuación 2.11:

$$\frac{P_{exit_{rx}}}{P_{in_{tx}}}(dB) = 10 \log_{10} \left(\frac{P_{exit_{rx}}}{P_{in_{tx}}} \right) = 10 \log_{10} \left\{ \left(\frac{\lambda}{4\pi d} \right)^2 (G_{rx} G_{tx}) \right\} \quad (2.11)$$

$\frac{P_{exit_{rx}}}{P_{in_{tx}}}(dB)$: ecuación de transmisión de Friis en dB

d : distancia entre el emisor y el receptor (m)

G_{rx} : Ganancia de la antena del receptor (dBi)

G_{tx} : Ganancia de la antena del transmisor (dBi)

- Pérdida de trayectoria.** La pérdida de trayectoria numérica relaciona la EIRP con la potencia disponible en el receptor. A veces, para mayor claridad, esta relación con línea de visión directa se denomina pérdida de trayectoria isotrópica en espacio libre (PL_{fs}) (Bensky, 2019). Esto significa que las antenas del transceptor, tanto transmisoras como receptoras, utilizan comunicación con LOS, sin obstrucciones ni reflexiones de ningún tipo. Sin embargo, si las antenas están situadas cerca del suelo, la ecuación anterior no es válida por la reflexión de la tierra (Vougioukas et al., 2013). La figura 2.3 aclara esta sentencia mostrando que la energía direccionada que emite la antena transmisora hacia la receptora es $EIRP = P_{in_{tx}} G_{tx}$, la potencia a la salida de la antena receptora es $P_{exit_{rx}} = P_{in_{rx}} G_{rx}$, por tanto la pérdida de trayectoria (PL_{fs}) tiene la igualdad de la ecuación 2.12,

$$PL_{fs} = \frac{P_{in_{rx}}}{EIRP} = \frac{\left(\frac{P_{exit_{rx}}}{G_{rx}} \right)}{P_{in_{tx}} G_{tx}} = \left(\frac{P_{exit_{rx}}}{P_{in_{tx}}} \right) \left(\frac{1}{G_{tx} G_{rx}} \right) \quad (2.12)$$

Reemplazando $\left(\frac{P_{exit_{rx}}}{P_{in_{tx}}} \right)$ con la igualdad de la ecuación 2.11 se obtiene la ecuación 2.13 (Bowrothu y Yoon, 2020),

$$PL_{fs} = \left(\frac{\lambda}{4\pi d} \right)^2 (G_{rx} G_{tx}) \left(\frac{1}{G_{rx} G_{tx}} \right) = \left(\frac{\lambda}{4\pi d} \right)^2 \quad (2.13)$$

y teniendo en cuenta que $\lambda = \frac{c}{f_c}$

$$PL_{fs} = \left\{ \frac{c}{4\pi f_c d} \right\}^2 \quad (2.14)$$

En escala logarítmica (Halbauer y Wild, 2021),

$$PL_{fs}(\text{ dB}) = 20 \log \left\{ \frac{c}{4\pi f_c d} \right\} \quad (2.15)$$

Por tanto, el PL_{fs} puede expresarse en decibelio (dB) como la ecuación 2.16

$$PL_{fs}(\text{ dB}) = 20 \log(f) + 20 \log(d) - 147,56 \quad (2.16)$$

donde f se expresa en Hz y la distancia d en metros (Mahesh et al., 2013; Rama Rao et al., 2012).

- **Modelo de propagación de “Dos-Rayos”**. Cuando la radiofrecuencia se propaga cerca del suelo con LOS, puede utilizarse el modelo de propagación de onda de tierra plana (PE) para definir la pérdida de trayectoria en lugar del modelo $PL_{Espaciolibre}$. Este modelo incluye efectos de reflexión de los rayos del suelo y del rayo LOS, que viene dada por la ecuación $PL_{PE}(\text{ dB}) = 40 \log(d) - 20 \log(hT) - 20 \log(hR)$, donde d es la distancia entre las antenas del transmisor y receptor en metros, y hT y hR son las elevaciones de las antenas del transceptor también en metros, donde d es mucho mayor que hT y hR (Rogers et al., 2002).

2.3.4. Propagación con NLOS

Antes de estudiar los efectos de la vegetación sobre una señal en la banda de frecuencias de microondas que son sensibles a enlaces con NLOS se introducen a continuación los conceptos de pérdida total y presupuesto de enlace.

- **Pérdida total**. Las señales en frecuencias de microondas (1 - 30 GHz) (Frenzel, 2013) y milimétricas (30 - 300 GHz) experimentan dispersión y absorción causadas por hojas y ramas de la vegetación distribuidas aleatoriamente (Agrawal y Garg, 2007). Las pérdidas totales de la trayectoria se formulan combinando las pérdidas del modelo $PL_{EspacioLibre}$, con las pérdidas de vegetación PL_{veg} que predicen diferentes modelos de vegetación,

$$PL_{tot} = PL_{EspacioLibre} + PL_{veg} \quad (2.17)$$

donde PL_{tot} es la pérdida total de la trayectoria (Sabri et al., 2018).

- **Presupuesto del enlace.** Agregando pérdidas de trayecto por NLOS (PL_{NLOS}) a la pérdida de trayecto por LOS (PL_{LOS}) obtenemos

$$PL_{tot} = PL_{NLOS} + PL_{LOS} \quad (2.18)$$

La $P_{out_{rx}}$ se define mediante la ecuación (Correia et al., 2017),

$$P_{out_{rx}} = P_{in_{tx}} + G_{rx} + G_{tx} - PL_{tot} \quad (2.19)$$

Reemplazando 2.18 en 2.19 tenemos

$$P_{out_{rx}}(dBm) = P_{in_{tx}} + G_{rx} + G_{tx} - PL_{NLOS} - PL_{LOS} \quad (2.20)$$

La ecuación expandida en 2.21, teniendo presente 2.15 queda como a continuación se muestra (Mikeka et al., 2014),

$$P_{out_{rx}}(dBm) = P_{in_{tx}} + G_{rx} + G_{tx} - PL_{NLOS} - 20 \log\left(\frac{4\pi}{\lambda}\right) - 20 \log(d) \quad (2.21)$$

2.4. Atenuación en presencia de vegetación

Dependiendo del grosor de la vegetación y la frecuencia de operación, una señal podría viajar difractada reduciendo el alcance de las comunicaciones de los equipos de radio. El conocimiento cuantitativo del exceso de pérdidas de propagación que sufren las ondas de radio debido a la presencia de vegetación es esencial para planificar un enlace de comunicaciones en cualquier terreno boscoso (Gay-Fernandez y Cuinas, 2014; Tejada y Reynoso, 2015; Tewari et al., 1990; Wong, 2014). Además de la atenuación en el espacio libre, las ondas electromagnéticas se desvanecen por mecanismos que incluyen difracción, reflexión, dispersión y absorción aleatoria dentro de la vegetación entre el transmisor y receptor (Djosic et al., 2022; Savage et al., 2003) similar a la observada en la figura 2.4.

Las ondas radiadas tienen efecto desconocido en su propagación exacta. Para determinar estos cambios, se utilizan modelos de propagación que estiman el área de cobertura radioeléctrica de un transmisor y muestran la intensidad de la señal entre el transmisor y receptor (de Sales Bezerra et al., 2015; Mestre et al., 2011; Paul y Rimer, 2012; Sabri et al., 2013).

La propagación multitrayecto de las ondas de radio entre los transceptores de los nodos WSN

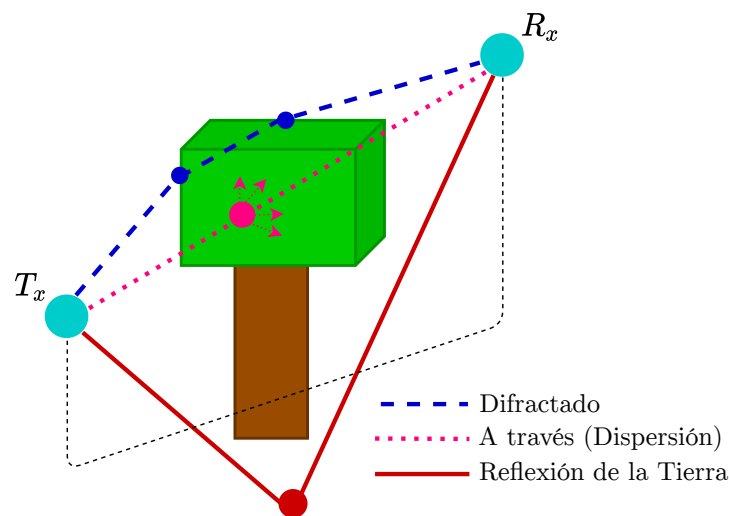


Figura 2.4: Posibles mecanismos de propagación en presencia de vegetación

(Celaya-Echarri et al., 2019; Picallo et al., 2019) se degrada debido a pérdidas de propagación (Khairunni et al., 2018) dentro del invernadero (Rahim et al., 2017; Yang et al., 2019) por falta de LOS (Khairunni et al., 2018), generando en consecuencia pérdida de potencia de la señal. El cálculo de esta pérdida determina la fiabilidad del enlace inalámbrico junto con el éxito de la aplicación objetivo del despliegue de la WSN (Caicedo Ortiz, 2015; Montoya et al., 2013). Su conocimiento permite la creación de modelos más adecuados en el diseño de la comunicación inalámbrica (Popov, 2019). En este estudio, modelamos la propagación de las ondas de radio a partir del RSSI, una medida obtenida a través de la potencia recibida de las señales inalámbricas a diferentes distancias de transmisión y diferentes alturas de antena dentro de un invernadero de tomates (Brinkhoff y Hornbuckle, 2017). Esto sirve para establecer máxima distancia efectiva entre nodos y predecir el número de sensores necesarios que cubren el despliegue de la WSN en una zona de cultivo (Picallo et al., 2019). A continuación aclaramos la explicación de conceptos de pérdida de propagación y presupuesto de enlace.

La modelización de la propagación de las ondas electromagnéticas es una herramienta esencial para el diseño de redes inalámbricas y los estudios de interferencias de radiofrecuencia (RF) (Montero y Araque, 2018). Como se ha descrito anteriormente, estos modelos pueden dividirse en dos categorías: empíricos (o estadísticos) y deterministas (analíticos). Los modelos empíricos son más utilizados para resolver problemas prácticos y se basan en mediciones reales de RF en canales de comunicación. Estos modelos son sencillos de aplicar y pueden ofrecer solución rápida. Sin embargo, sus predicciones no siempre son precisas. A diferen-

cia de los modelos empíricos, los modelos deterministas de mayor complejidad, se basan en aproximaciones numéricas a las ecuaciones de Maxwell que mejoran significativamente la fiabilidad de las predicciones (Lytaev y Vladyko, 2018; Sabri et al., 2018). Los modelos estadísticos se desarrollaron originalmente para proporcionar estimaciones sin datos de campo (Militaru et al., 2018). Los modelos empíricos basados en métodos de regresión se utilizan comúnmente para estimaciones de cobertura, dependiendo del tipo de vegetación donde se realizaron mediciones (Granda et al., 2018; Raheemah et al., 2016). Los modelos de radio-propagación más utilizados para el diseño de redes inalámbricas en presencia de vegetación son los empíricos (Balachander et al., 2013; Chee et al., 2011; Cuinas y Gay-Fernandez, 2014; Khairunni et al., 2018; Mani y Oestges, 2012; Meng y Lee, 2010; Mestre et al., 2010; Oroza et al., 2017; Rahim et al., 2017; Rahman et al., 2013; Sabri et al., 2012; Zakaria et al., 2017):

- **EDM:** El EDM modificado es el modelo empírico genérico (Khairunni et al., 2018; Montero et al., 2018).

$$L_{med} = Af^B d^C$$

f = Frecuencia (MHz), d = Profundidad de Vegetación (m)

Los parámetros del modelo A , B , C son constantes empíricas. Este modelo es el propuesto por la Unión Internacional de Telecomunicaciones (UIT).

Rango de Frecuencia: 30 MHz a 30 GHz

- **Weissberger:** (Raheemah et al., 2016; Rahim et al., 2017)

$$L_{Weiss} = 0,45f^{0,284}d, 0m < d < 14m$$

$$L_{Weiss} = 1,33f^{0,284}d^{0,558}, 14m < d < 400m$$

Donde f es la frecuencia en GHz y d es la profundidad de la vegetación en metros.

Rango de Frecuencia: 230 MHz a 95 GHz

- **ITU-R:** (Rahim et al., 2017)

$$L_{ITU-R} = 0,2f^{0,2}d^{0,6}, d < 400m$$

Donde f es la frecuencia en MHz y d es la profundidad de la vegetación en metros.

Rango de Frecuencia: 200 MHz a 95 GHz

- **COST235:** (Raheemah et al., 2016; Rahim et al., 2017; Shutimarrungson y Wuttidittachotti, 2019)

$$L_{COST235} = 26,6 f^{-0,2} d^{0,5} \text{ fuera de hoja}$$

$$L_{COST235} = 15,6 f^{-0,009} d^{0,26} \text{ dentro de hoja}$$

Donde f es la frecuencia en MHz y d es la profundidad de la vegetación en metros, $d < 200m$.

Rango de Frecuencia: 9,6 GHz a 57,6 GHz

- **FITU-R:** Fitted ITU-R (Raheemah et al., 2016; Rahim et al., 2017; Shutimarrungson y Wuttidittachotti, 2019)

$$L_{FITU-R} = 0,37 f^{-0,18} d^{0,59} \text{ fuera de hoja}$$

$$L_{FITU-R} = 0,39 f^{-0,39} d^{0,25} \text{ dentro de hoja}$$

Donde f es la frecuencia en MHz y d es la profundidad de la vegetación inferior a 400 m.

Rango de Frecuencia: VHF a ondas milimétricas

Como se puede comprobar, en general los modelos empíricos de atenuación por vegetación dependen de la frecuencia de las ondas de radio y distancia en profundidad de la vegetación. Sin embargo, sus predicciones difieren considerablemente con resultados obtenidos en pruebas de campo. Por ello, en este trabajo presentamos un novedoso método general para determinar un modelo empírico de atenuación por vegetación.

Los cinco modelos anteriores expresan el exceso de atenuación en dB de un obstáculo en la trayectoria de propagación; los cuatro últimos modelos están basados en el primero, es decir, en el modelo básico EDM. Estos son aplicables en situaciones donde es probable que la propagación se produzca atravesando una arboleda y no por difracción en la copa del árbol (Rahman et al., 2013; Rao et al., 2016; Sabri et al., 2013). En ese sentido, la intensidad de la señal recibida para sistemas inalámbricos en medios con vegetación se basa en gran medida en modelos empíricos que son relativamente fáciles de utilizar (Rahman et al., 2017).

2.5. La Inteligencia Artificial y Deep Learning

Con el propósito de encontrar una relación entre las variables no independientes involucradas en la atenuación de la onda de radio en presencia de cultivo, se ha explorado la posibilidad de utilizar técnicas de aprendizaje automático (Machine Learning, ML) (Liu et al., 2022) que junto con las redes neuronales son dos enfoques interrelacionados que soportan a la Inteligencia artificial (IA) (Agliari et al., 2022). De este modo en ML se construye un modelo automáticamente, deduciendo ideas significativas (conocidas como características) del conjunto de datos, siendo la extracción de estas características el paso más crítico en la generación del modelo (Orellana Figueroa et al., 2021). Posteriormente las características no lineales de los datos de entrada establecen interacciones y relaciones con las variables de predicción de salida (Wang et al., 2022). De manera análoga, los seres humanos utilizamos un modelo del mundo como simulador en nuestro cerebro. Dicho modelo es obtenido aprendiendo de grandes cantidades de datos recogidos por nuestros sentidos interactuando con el entorno que nos rodea (Matsuo et al., 2022).

El aprendizaje en ML recopila datos de entrada y salida para predecir posteriormente los valores futuros; sus algoritmos de aprendizaje automático son el supervisado, que contiene descriptores de características creados manualmente, y el no supervisado que aprende por sí misma, de la experiencia, características ocultas en el conjunto de datos desarrollando su propia representación (comprimida y probabilística) a fin de generalizar e identificar correctamente nuevos ejemplos (Agliari et al., 2022; Sharma y Mandal, 2023; Srinivasan y Jagatheeswari, 2023).

En la implementación de algoritmos de aprendizaje automáticos se pueden utilizar redes neuronales artificiales (ANN) (Mishra y Gupta, 2017) cuyo modelos matemáticos siguen el principio del cerebro humano para procesar la información. Esto quiere decir que la información es enviada y recibida de neurona a neurona contigua hasta llegar finalmente al cerebro. El modelo considera a la neurona como una unidad de computación conectada a través de líneas ponderadas formando una red jerárquica (Li et al., 2022; Muthukumaran et al., 2023). Las regiones conteniendo neuronas se denominan capas, y generalmente se pueden distinguir tres capas: la capa de entrada, capa de salida y la capa oculta que comunica las dos anteriores (Mrabti et al., 2023). Mientras más se eleve el número de capas ocultas, la ANN será más compleja, significando que sus modelos tendrán mayor capacidad de predicción y cálculo (Dai, 2021).

Por su arquitectura, las ANN pueden clasificarse en redes neuronales convolucionales (CNN) y redes neuronales recurrentes (RNN). Los nodos o neuronas de la CNN detectan características locales del vector de entrada y las capas posteriores combinan estas características. Un ejemplo clásico de aplicación de las CNN es en detección del subtítulo de imágenes y respuesta a preguntas visuales más que en reconocimiento de acciones (Sergeev, 2019; Vaz y Balaji, 2021; Wickramanayake et al., 2021). Las RNN, por el contrario, son redes que muestran un comportamiento dinámico mediante el aprendizaje de tareas temporales aprendiendo las dependencias históricas de los datos (Berhich et al., 2022; Vaz y Balaji, 2021).

El aprendizaje profundo (DL) es una forma o subcampo del ML (Escamilla-Rivera et al., 2022; Farris et al., 2021). La ANN son los algoritmos principales de la DL. Si la profundidad o número de capas de la ANN es mayor a tres, dejará de ser una simple ANN para convertirse en un algoritmo DL (Kavlakoglu, 2020), llamado red neuronal profunda (DNN), permitiendo interpretar exitosamente entradas no lineales más complejas (Bengio et al., 2021). Por ello, los sistemas DL tienen como objetivo el aprendizaje automático de jerarquías de características multicapa a partir de datos con los que se entrena para tareas concretas, siendo este entrenamiento la fase computacional más costosa (Franchini et al., 2023; Lecun, 2019; Ranzato et al., 2015).

Aunque no hay investigaciones que usen ML en la estimación de la pérdida de radio propagación ante la presencia de vegetación, entre la literatura revisada encontramos pocas investigaciones afines. Entre ellas está el uso de ML basado en DNN que emplea CNN para la estimación de la pérdida de propagación radio-eléctrica teniendo la información espacial como mapas de ocupación de edificios como datos de entrada (Ito y Hayashi, 2021). Otro estudio para pronosticar la pérdida de trayectoria en zonas rurales usando la banda de 3.7 GHz, combina diferentes modelos ML, donde para la etapa de aprendizaje de la base utiliza ANN, árboles de decisión (DT), regresión de vectores de soporte (SVR), k-Nearest Neighbors (kNN), el modelo lineal generalizado (GLM) y una DNN personalizada con 3 capas ocultas como meta-aprendizaje (Moraitis et al., 2022). El artículo de (Bogdándy y Tóth, 2021) usa el registro de valores RSSI WiFi como datos de entrada en la red neuronal artificial de inversión para determinar el posicionamiento de los nodos en interiores. La inversión es uno de los tres métodos de operación en las implementaciones de redes neuronales artificiales además de entrenamiento y predicción. También (Seretis et al., 2020) emplearon ML para obtener un modelo basado en ANN que predice las características de pérdidas de radio propagación en el interior de túneles.

Capítulo 3

Fundamento Teórico

3.1. Antecedentes

Los modelos empíricos clásicos o tradicionales (por ejemplo UIT-R, la UIT-R y la FSPL), comentados en el anterior capítulo, determinan que la atenuación de la señal causada por el follaje ($L_{follaje}$) es función de la frecuencia y distancia de los nodos inalámbricos. Sin embargo, estas difieren notablemente de las pruebas en campo (Richardson Ansah et al., 2020). Hay investigaciones tales como (Raheemah et al., 2015) y (Li et al., 2014) que consideran que debe haber también una dependencia de la atenuación de la señal con la altura de las antenas respecto al suelo.

Se han realizado varios estudios para mejorar las predicciones a través de modelos novedosos que sí introducen la variable altura de la antena debido a que el follaje en los cultivos tiene diferente densidad a diferentes envergaduras. Entre ellos destacamos algunos que emplean regresiones lineales (Raheemah et al., 2016) (Vougioukas et al., 2013).

En una primera fase de la investigación, se verificó en mediciones hechas dentro de invernaderos de tomate la considerable inexactitud en los mencionados modelos empíricos con porcentajes de error del orden del 30%. Como consecuencia, en un primer estudio se desarrolló un modelo basado en regresiones lineales y cúbicas (Cama-Pinto et al., 2019) con el objetivo de mejorar las discrepancias que encontrábamos de los modelos con la realidad. En el modelo empírico definido pudimos constatar que las mediciones de la atenuación en pruebas de campo manifestaban curvas con error inferior al 9%.

Ahora bien, tanto en el trabajo realizado en (Cama-Pinto et al., 2019) como en otros estudios similares los modelos empíricos obtenidos se han elaborado a partir de las mediciones registradas en las pruebas de campo sin determinar claramente los límites de aplicación de dichos modelos, por lo que pueden obtenerse distintas soluciones por su dependencia con las medidas experimentales. Esto significa que no hay unicidad en la solución obtenida y se necesita aportar información de la función de coste utilizada para optimizar el modelo y así evitar o reducir el posible sesgo o variabilidad. En ese sentido, un problema mal condicionado o mal planteado está definido como un problema con soluciones inestables, sin solución única o no es una función continua de los datos.

La contaminación invariable de datos con ruido se adquieren en un número limitado de puntos de observación generando problemas mal planteados. Por tanto, si una pequeña perturbación arbitraria de los datos puede causar una gran perturbación arbitraria de la solución, se trata de un sistema mal condicionado que amplifica el ruido e introduce errores en la estimación de parámetros a predecir. Es obvio que en problemas mal planteados no se conseguirá una solución adecuada empleando técnicas tradicionales. Para mitigar dichos errores en el problema mal condicionado se emplean estrategias como regularización (Abdelazeem, 2013; Save et al., 2012). La estimación de la atenuación de la señal en presencia de vegetación depende además de la frecuencia, también de la altura y distancia entre nodos. La obstrucción provocada por la compleja estructura de la plantación de cultivos que impiden la línea de vista entre los nodos obliga a resolver un sistema de ecuaciones mal condicionado.

3.2. Método de determinación de la atenuación mediante regresión regularizada

Teniendo en cuenta que en los métodos empíricos es inherente la exposición del modelo a medidas espureas que pueden proporcionar sesgo o variabilidad y, por tanto, una mala estimación de la atenuación, vamos a considerar el problema como un problema mal condicionado.

Este tipo de modelos o sistemas suelen denominarse problemas lineales discretos mal planteados 3.1, con una matriz H mal condicionada de rango mal determinado (Calvetti et al., 2000).

$$Hx = y \tag{3.1}$$

donde

y : vector de observación $m \times 1$

x : vector de estado $n \times 1$ que debe estimarse

H : matriz de información $m \times n$; $m \geq n$ donde n es el número de variables de estado a estimar y m es el número total de observaciones y relacionan los cambios en el modelo con los cambios en los datos (Jia y Yang, 2020).

El vector x representa las actualizaciones de los coeficientes de referencia (Swenson y Wahr, 2011), e y es el vector de medida, que tiene los residuos de los datos (por ejemplo, diferencias entre datos observados y predichos), y suele estar contaminado por el error de observación e (vector $m \times 1$) que perturba las mediciones u observaciones exactas desconocidas de \hat{y} (vector $m \times 1$) (Calvetti et al., 2004):

$$y = \hat{y} + e \quad (3.2)$$

Dado su carácter mal planteado, la solución directa del problema es inestable, y una pequeña perturbación de los datos puede causar grandes perturbaciones en la solución (Sun et al., 2018). Estos problemas están mal planteados debido al gran número de condiciones de H y la técnica más común para resolverlos es el método de regularización (Liu et al., 2020), siendo la regularización de Tikhonov el método de regularización más exitoso de todos los tiempos. (Liu y Wang, 2022; Shehab y Kahraman, 2018).

La regularización de Tikhonov, en vez de resolver el sistema lineal de la ecuación 3.1 determina la solución del problema de minimización de la ecuación 3.3:

$$x_a = \arg \min_{x \in R^n} \frac{1}{2} \|Hx - y\|^2 + \frac{\mu}{2} \|x\|^2 \quad (3.3)$$

La función de coste está definida en la ecuación 3.4 (Sakumura et al., 2016) y trata de determinar el error entre el valor estimado y el valor real. Con el fin de optimizar los parámetros del modelo en Matlab usamos la función `costFunctionReg.m` (Vu, 2015).

$$J = \|Hx - y\|^2 + \mu \|x\|^2 \quad (3.4)$$

donde μ en la regularización de Tikhonov se calcula a partir del criterio de la curva- L (Tangdamrongsub et al., 2012). Puesto que para cada parámetro regularizador μ tiene una solución distinta x_μ , cada solución x_μ asociada a ese μ contendrá un error que será $Hx_\mu - y$. Con eso se construye una curva que se denomina curva- L definida por la ecuación 3.5. La curva- L es enfrentar el error ($Hx_\mu - y$) cometido para cada solución asociada a μ respecto a x_μ .

$$\mathcal{L} = \left(\log \|Hx_\mu - y\|, \log \|x_\mu\| \right) : \mu \geq 0 \quad (3.5)$$

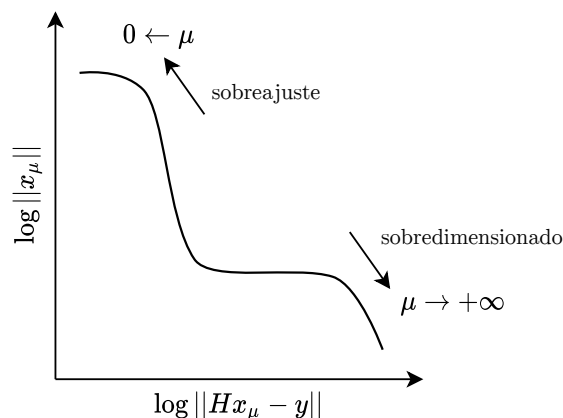


Figura 3.1: Curva- L es un gráfico logarítmico del termino de regularización $\|x_\mu\|$ versus el residuo $\|Hx_\mu - y\|$ (Hansen, 1998)

La curva- L , corazón de todo método de regularización, es un gráfico logarítmico para todos los μ válidos que exhibe el compromiso entre minimización de la norma residual $\|Hx - y\|$ frente a la norma de restricción $\|x_\mu\|$ (Save et al., 2012). Si se elige μ demasiado grande ($\mu \rightarrow \infty$), x_μ debe minimizarse. La reconstrucción correspondiente de x_μ no será una buena solución para el sistema lineal $Hx = y$, por que pierde muchos detalles estando sobredimensionada. Por el contrario, si se elige μ demasiado pequeño ($\mu \rightarrow 0$), debe minimizarse el residuo $Hx_\mu - y$. Sin embargo, esto significa que los errores de medición e no se suprimen y la reconstrucción x_μ estará sobreajustada a las mediciones (Cornelis et al., 2020).

Por tanto, las buenas elecciones de μ son valores intermedios, donde términos de regularización y error se equilibran siendo ambos pequeños (Gazzola et al., 2020; Lehnert et al., 2018; Save et al., 2012).

El uso de la técnica de regresión regularizada es novedoso en este análisis, dado que evalúa y busca que el sobreajuste (overfitting) o sobredimensionado (oversmoothed) en el modelo

propuesto sea lo más objetivo posible, aportando información a la función de coste que está débilmente formulada en un inicio.

Para ello, buscamos una ecuación polinómica que determine la atenuación de una señal tomando como referencia el modelo empírico EDM. Es decir, se incluye en la ecuación la altura del receptor descrita en la ecuación 3.6 y además se establece además arbitrariamente una cantidad de 40 parámetros que son reducidos posteriormente.

$$L_{\text{follaje}}(d, h) = \theta_1 + \theta_2 f^{\theta_0} d^{\theta_3} h^{\theta_4} + \sum_{k=5}^{40} \theta_k d^i h^j \forall i, j = \{0, 1, 2, \dots, 5\} \quad (3.6)$$

donde los parámetros son $\{\theta_1, \theta_2, \dots, \theta_k\}$, f^{θ_0} es el valor de la frecuencia de emisión (valor constante porque evaluamos en la banda ICM de frecuencia central de 2,4 GHz), d es el valor de la distancia entre emisor y receptor, y h el valor de las alturas del receptor y del emisor.

L_{follaje} se ha desarrollado para un polinomio de quinto grado. La selección del grado del polinomio responde a la necesidad de tener un grado suficientemente grande para explicar el comportamiento físico de la atenuación. Un polinomio de grado 5 (i, j de 0 a 5) es suficientemente grande para explicar este comportamiento físico de la atenuación. La mayor parte de esta optimización se alcanza mediante la ecuación 3.8, función coste $J(\theta)$, empleando el algoritmo de optimización basado en Nelder-Mead método simplex (Lagarias et al., 1998). El algoritmo Nelder Mead (NM) minimiza o maximiza una función objetivo en un espacio multidimensional sin restricciones (Amali. D y M, 2018) y está elaborada como la función `fminsearch` de Matlab (Petras, 2019). Es una de las mejores técnicas de optimización por ser uno de los métodos más rápidos y sencillos para resolver problemas de mínimos locales y de optimización multidimensional (Nawaz et al., 2017). Se basa en la búsqueda directa para problemas complejos multivariables sin restricciones. (Mohsin et al., 2021), denominándose también método “simplex” (Aydin et al., 2019) o algoritmo de búsqueda simplex.

El método iterativo del algoritmo NM pertenece a la clase de métodos de búsqueda directa. Su principal propiedad es que no requiere calcular o estimar derivadas de la función a optimizar. En su lugar, se basan exclusivamente en valores de la función objetivo.

El objetivo del método consiste en resolver el problema sin restricciones mín $f(x)$ donde $x \in \mathbb{R}^n$, siendo n el número de parámetros de la función de coste a optimizar, definida como $f : \mathbb{R}^n \rightarrow \mathbb{R}$ (Suriano et al., 2020).

En esta investigación, un "problema mal planteado" se resuelve a partir de la regularización de Tikhonov optimizándose añadiendo la norma de la solución a la función de coste como se aprecia en la siguiente ecuación 3.7 (Calvetti et al., 2000; Shi et al., 2022):

$$\min_{\theta \in R^n} \|L_{\text{follaje}}(\theta) - dB\|^2 + \lambda \|\theta\|^2 \quad (3.7)$$

donde $L_{\text{follaje}}(\theta)$ es la atenuación en función de θ , dB son los valores experimentales medidos de la atenuación, $\lambda > 0$ es el parámetro de regularización, y $\|\cdot\| = \|\cdot\|^2$ es la norma euclidiana.

La prevención del sobreajuste de las variables se realiza mediante el término regularizador (regularización de Tikhonov) (Franklin, 1974; Provencher, 1982a,b), donde λ es el término regularizador y determina el peso que deben tener los parámetros en la función de coste. Este tipo de problema garantiza que no haya un sobreajuste en las funciones parametrizadas. Para este problema de optimización es necesario calcular los gradientes de cada dirección. La ecuación 3.8 muestra cómo se pueden calcular estos gradientes.

$$\begin{aligned} J(\theta) &= \|L_{\text{follaje}}(\theta) - dB\|^2 + \lambda \|\theta\|^2 \\ \frac{\partial J(\theta)}{\partial \theta_1} &= 2 \|L_{\text{follaje}}(\theta) - dB\| \frac{\partial L_{\text{follaje}}^{(m)}}{\partial \theta_1} + 2\lambda \|\theta\| \\ \frac{\partial J(\theta)}{\partial \theta_2} &= 2 \|L_{\text{follaje}}(\theta) - dB\| \frac{\partial L_{\text{follaje}}^{(m)}}{\partial \theta_2} + 2\lambda \|\theta\| \\ &\dots \\ \frac{\partial J(\theta)}{\partial \theta_n} &= 2 \|L_{\text{follaje}}(\theta) - dB\| \frac{\partial L_{\text{follaje}}^{(m)}}{\partial \theta_n} + 2\lambda \|\theta\| \end{aligned} \quad (3.8)$$

Con el fin de resumir el procedimiento para encontrar valores de los parámetros θ apoyado en la función de coste, resumimos el procedimiento en los siguientes siete (7) pasos:

1. Se elige un parámetro regulador λ arbitrario.
2. Se inicia la función de coste en la regularización de Tikhonov:

$J(\theta) = \|L_{\text{follaje}}(\theta) - dB\|^2 + \lambda \|\theta\|^2$ considerando que $\theta = 0$, es decir todos sus parámetros son cero, haciendo que $J(\theta)$ sea muy grande.

θ : Es un vector que contiene parámetros $\theta_1, \theta_2, \theta_3, \theta_4, \dots, \theta_n$

3. Se envía al algoritmo de Nelder-Mead (NM) el valor de

$\frac{\partial J(\theta)}{\partial \theta_1}, \frac{\partial J(\theta)}{\partial \theta_2}, \frac{\partial J(\theta)}{\partial \theta_3} \dots \frac{\partial J(\theta)}{\partial \theta_n}$. El algoritmo NM de acuerdo a lo que recibe propone el siguiente valor de θ .

4. Con este nuevo valor propuesto de θ se repite el algoritmo de NM en el paso 2 y paso 3 iterativamente hasta encontrar valores idóneos del vector (θ) .
5. Se repiten los pasos del 1 al 4 para otro λ .
6. Usando el criterio de la curva L , se elige el λ_{optimo} que determina el vector de parámetros θ óptimos (ver figura 3.2).
7. Se evalúa el rendimiento del modelo.

La ecuación 3.6, conteniendo 40 parámetros, es tratada con pasos del 1 al 6 del procedimiento antes descrito eliminando los parámetros θ con valores menores o iguales a 0,01 porque su contribución es despreciable al modelo. Esto nos deja una nueva ecuación 3.9 de 20 parámetros:

$$\begin{aligned}
 L_{follaje}(d, h) = & \theta_1 + \theta_2 d^{\theta_3} h^{\theta_4} + \theta_5 d^2 h + \theta_6 d h^2 + \theta_7 d^2 h^2 + \theta_8 d^3 h \\
 & + \theta_9 d^3 h^2 + \theta_{10} d^3 h^3 + \theta_{11} d^2 h^3 + \theta_{12} d h^3 + \theta_{13} d^2 \\
 & + \theta_{14} h^2 + \theta_{15} d^3 + \theta_{16} h^3 + \theta_{17} d^4 + \theta_{18} h^4 + \theta_{19} d^5 + \theta_{20} h^5 \quad (3.9)
 \end{aligned}$$




Figura 3.2: El λ_{optimo} en la regularización de Tikhonov de nuestro modelo es elegido a partir del criterio de la curva- L indicado por el triángulo rojo (Fahmi et al., 2016)




Figura 3.3: Esquema del modelo de aprendizaje profundo para la estimación de la atenuación a partir de la distancia y la altura.

3.3. Método de determinación de la atenuación mediante aprendizaje profundo

Como un método alternativo se ha estudiado cómo se puede aplicar el aprendizaje profundo para la obtención de un modelo empírico de la atenuación teniendo en cuenta las mismas variables que se han considerado en el método de determinación por regresión regularizada.

Concretamente se ha propuesto diseñar un modelo empírico de atenuación basado en el aprendizaje profundo. Está compuesto por dos capas, una de codificación y otra de decodificación. La capa de codificación convierte en binario la distancia y la altura a la que se quiere conocer la atenuación. Esta codificación se realiza utilizando 14 bits para la distancia y 11 bits para la altura, dando dos números reales con dos decimales a 25 bits en total. La decodificación convierte de binario a número real con una precisión de 3 decimales, utilizando 17 bits para realizar esta conversión a número real. La red neuronal está compuesta por 7 capas. La primera y la última son las capas de entrada y salida, respectivamente. El resto de las capas son ocultas. La figura 3.3 muestra la estructura de la red neuronal profunda. La función de activación de los perceptrones es la función sigmoidea. La capa de entrada tiene 25 perceptrones que corresponden a los 25 bits de entrada. Mientras que la capa de salida tiene 17 perceptrones que corresponden a los 17 bits de salida.

Los valores de distancia y altura componen el vector X , mientras que los valores de atenuación estimados $L_{foliage}(d, h)$ o los dB medidos son Y . La representación de los dos vectores X e Y se muestra en la figura 3.4.




Figura 3.4: Representación de la distancia y la altura. Esto compone el vector X mientras que los valores de atenuación estimados $L_{foliage}(d, h)$ los dB medidos están compuestos por Y . Los valores B son bits que pueden tomar los valores 0 o 1. Entonces, para crear el número real la distancia, la altura y $L_{foliage}(d, h)$ tienen una parte entera y otra decimal.

El ajuste paramétrico de la red neuronal profunda se realiza minimizando la siguiente función de coste,

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \sum_{k=1}^K \left[-y^i \log \left(h_{\theta} \left(x^i \right) \right) - \left(1 - y^i \right) \log \left(1 - h_{\theta} \left(x^i \right) \right) \right] \quad (3.10)$$

donde m es el número de experimentos realizados y K es el número total de bits en la capa de salida. La función logística se define como

$$h_{\theta} = g(\theta^T x) \quad (3.11)$$

donde g es la función sigmoidea,

$$g(z) = \frac{1}{1 + e^{-z}} \quad (3.12)$$

Para evitar las desviaciones y el sobreajuste de los parámetros de la función de costes de la ecuación 3.10, se añade la función de regularización de Tikhonov (Ezuma et al., 2022; Faroughi et al., 2022; Farris et al., 2021) de la siguiente manera,

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \sum_{k=1}^K \left[-y^i \log \left(h_{\theta} \left(x^i \right) \right) - \left(1 - y^i \right) \log \left(1 - h_{\theta} \left(x^i \right) \right) \right] + \frac{\lambda}{2m} \left[\sum_{n=1}^{N-1} \sum_{j=1}^{J_n} \sum_{s=1}^{S_n} \left(\theta_{j,s}^{(n)} \right)^2 \right] \quad (3.13)$$

Los parámetros de la red están representados por $\theta_{j,s}^{(i)}$ donde N es el número de capas, J_n es el número de conexiones entrantes totales en la capa n -ésima y S_n es el número de conexio-

nes entrantes totales en la capa n-ésima. λ es el término regularizador y determina el peso que deben tener los parámetros en la función de costes. Este tipo de problema garantiza que no haya sobreajuste y variabilidad en las funciones parametrizadas. Para este problema de optimización, es necesario calcular los gradientes para cada dirección. Los gradientes pueden calcularse mediante el algoritmo de retropropagación:

Algoritmo de retroceso	
1	Tienes el conjunto de entrenamiento: $\left\{ \left(\mathbf{x}^{(1)}, \mathbf{y}^{(1)} \right), \left(\mathbf{x}^{(2)}, \mathbf{y}^{(2)} \right), \dots, \left(\mathbf{x}^{(m)}, \mathbf{y}^{(m)} \right) \right\}$
2	Para todo el paquete de formación
3	Establece $\Delta_{ij}^{(n)} = 0$
4	Calcular la propagación hacia delante
5	Calcular la función de coste regularizada $J(\theta)$
6	Fijar $a^{(1)} = x^{(i)}$
7	Realizar la propagación hacia delante para calcular $a^{(n)}$ para $n = 2, 3, \dots, N$
8	Utilizando $y^{(i)}$, calcular $\delta^{(n)} = a^{(N)} - y^{(i)}$
9	Calcular $\delta^{(N-1)}, \delta^{(N-2)}, \delta^{(N-3)}, \dots, \delta^{(2)}$
10	$\Delta_{ij}^{(n)} := \Delta_{ij}^{(n)} + a_j^n \delta_i^{(n+1)}$
11	$D_{ij}^{(l)} := \frac{1}{m} \Delta_{ij}^{(n)} + \lambda \theta_{ij}^{(n)}$ if $j \neq 0$
12	$D_{ij}^{(l)} := \frac{1}{m} \Delta_{ij}^{(n)}$ if $j = 0$
13	$\frac{\partial}{\partial \theta_{ij}^{(n)}} J(\theta) = D_{ij}^{(n)}$

Una vez calculados los gradientes, se utiliza el método Polac-Ribiere (Yoon et al., 2021a) para calcular los gradientes conjugados para estimar la dirección de búsqueda. La aproximación se realiza mediante funciones polinómicas cuadráticas. El criterio de parada utilizado es el denominado condiciones de Wolfe-Powel (Rasmussen y Williams, 2006; Wolfe, 1969).

El número total de parámetros condiciona tanto el tiempo de entrenamiento como la densidad de perceptrones en la red neuronal. Se estudia el número de parámetros para un valor determinado de λ . La figura 3.5 relaciona el error en la predicción del valor de la atenuación con el número de perceptrones de la red.

El número óptimo de perceptrones de la red neuronal es 15575. Siguiendo esta arquitectura,




Figura 3.5: Valores de validación cruzada del RMSE para establecer el número de perceptrones. Se fija en 15575 distribuidos en 7 capas.

se optimiza el valor de λ eligiendo valores de 0,1, 0,01, 0,001 y 0,0001, dando como resultado la siguiente figura 3.6.

El resultado sugiere el mejor valor de λ . El error cuadrático medio (RMSE) se mantiene constante cuando λ se acerca a 0,001. Entonces, el valor óptimo se establece en 0,001. El valor de λ se utiliza en el algoritmo de retropropagación para evitar el sesgo y el sobreajuste.

3.4. Evaluación de los modelos

El rendimiento predictivo de los modelos se evalúan mediante los siete criterios de la tabla 3.1: El error cuadrático medio (MSE), raíz del error cuadrático medio (RMSE), error porcentual absoluto medio (MAPE), coeficiente de determinación (R^2), coeficiente de determinación ajustado (R^2_{adj}), criterio de información de Akaike (AIC), y el criterio de información bayesiano BIC, denominado también criterio de información de Schwarz - SBC. La descripción y fórmulas de estos indicadores figuran se encuentran en la tabla 3.1.

Estos indicadores son utilizados para medir si el valor previsto es similar al valor real. El MSE y RMSE evalúan el grado de variabilidad de los datos por ser medidas del error medio (Lyu et al., 2022). El MSE, también conocido como desviación cuadrática media, mide el grado que la muestra se desvía del valor predicho por el modelo. Mientras menor sea el MSE mayor precisión tendrá el ajuste del modelo, indicando cero que no hay error (Sen et al.,




Figura 3.6: Validación cruzada del RMSE. El valor óptimo de λ está ajustado cerca de 10^{-3} .

2022). El valor ideal del RMSE es cero, que refleja precisión de la medición, siendo muy sensible al error grande o pequeño en un grupo de mediciones (Lyu et al., 2022). El RMSE para validación cruzada (RMSECV) fue calculado usando la fórmula RMSE de la tabla 3.1 (Short et al., 2007; Song et al., 2022), eligiéndose el de menor valor (Peng et al., 2014) para comparar el error de predicción de cada modelo (Yoon et al., 2021b) evitando "sobreajuste" (Obisesan et al., 2020; Yin Yap y Seng Chia, 2021). De manera similar, el MAPE puede usarse para determinar lo bien que diferentes modelos evalúan los mismos datos, los valores más bajos denotan que el valor predicho se acerca al real. De esa forma cero expresa relación estrecha y uno aleatoria. (Chang et al., 2021; Faroughi et al., 2022).

La exactitud o evaluación del rendimiento del modelo puede verificarse por R^2 y su variante R^2_{adj} (Aziz et al., 2021; Cesari et al., 2021). Los modelos con altos valores de R^2 y R^2_{adj} cercanos a la unidad son los que funcionan con mejor concordancia entre valores medidos y predichos, mientras que cercanos a cero denotan débil relación entre ellos (Alavi et al., 2013; Qadir et al., 2021; Sallehudin y Diab, 2021). A diferencia del R^2 que aumenta siempre al añadir más parámetros hasta llegar a un modelo perfectamente ajustado, R^2 de validación cruzada (Q^2) aumenta cuando se añaden predictores útiles, pero disminuye en caso contrario. Al igual que R^2 , es mejor el modelo cuando Q^2 sea mayor (Ghorbel et al., 2021); a través de la fórmula R^2 es expresada Q^2 en la tabla 3.1 (Gramatica, 2013).

Por otro lado, AIC, y SBC son ampliamente utilizados para la selección de modelos (Banks

y Joyner, 2019; Banteng et al., 2019; Gohain y Jansson, 2022). AIC proporciona estimación de la información que se perdería utilizando un modelo concreto para describir el proceso que produjo los datos analizados (Tozzi et al., 2020). Cuanta menos información pierda un modelo, mayor será su calidad, logrando que el modelo de mejor ajuste sea el que tenga más bajo valor de AIC (Benedet et al., 2022; Bhattacharya et al., 2020). Este criterio implica que añadir más parámetros en el modelo mejora la bondad del ajuste, pero también aumenta la penalización impuesta al añadir más parámetros (Pham, 2019). Por su parte, SBC mide compromiso entre el ajuste del modelo y su complejidad, que toma en cuenta la bondad estadística del ajuste y el número de parámetros que tienen que ser estimados (Aguilera-Sáez et al., 2019; Tran et al., 2021). El mejor modelo tiene menores valores de AIC y SBC (Ezuma et al., 2022; Ikbali et al., 2022; Xu et al., 2017).

Tabla 3.1: Criterios de evaluación de modelos

	Criterio	Fórmula
R^2	Coefficiente de correlación múltiple de regresión no lineal (Franch et al., 2021)	$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$
R_{adj}^2	Coefficiente de determinación ajustado (Adusei et al., 2021)	$R_{adj}^2 = 1 - \frac{(n-1) \sum_{i=1}^n (y_i - \hat{y}_i)^2}{(n-k) \sum_{i=1}^n (y_i - \bar{y})^2}$
$MAPE$	Porcentaje medio de error absoluto (Atchadé y Sokadjo, 2022; Yang y Xing, 2021)	$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{ \hat{y}_i - y_i }{y_i}$
MSE	Error medio cuadrático (Gao y No, 2022; Hu et al., 2021)	$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$
$RMSE$	Error cuadrático medio (Dubrovin et al., 2022; Nazerian et al., 2021)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$
AIC	Criterio de información de Akaike (Albahli y Nabi Ahmad Hassan Yar, 2022; Gkioulekas y Papageorgiou, 2018)	$AIC = n \cdot \log \left(\frac{RSS}{n} \right) + 2k$
BIC	Criterio de información bayesiano (Macave et al., 2022; Urniezius et al., 2021)	$BIC = n \cdot \log \left(\frac{RSS}{n} \right) + \log(n) \cdot k$

Observación: n : número de muestras, y_i : i -ésimo valor medido experimentalmente, \hat{y}_i : i -ésimo valor predicho, RSS: Suma residual de cuadrados ($RSS = \sum_{i=1}^n (\hat{y}_i - y_i)^2$), k : número de parámetros del modelo.

Capítulo 4

Análisis experimental

Determinar la atenuación de la señal atravesando la vegetación es importante en la SF para saber cómo deben desplegarse los nodos de la WSN en un invernadero. Con el propósito de realizar las validaciones necesarias con los modelos a lo largo de esta tesis se ha desarrollado un sistema de medición RSSI que registra valores de intensidad de la señal entre un nodo de transmisión y otro receptor a diferentes distancias y alturas.

4.1. Sistema de medición de atenuación de ondas de radio en invernaderos

Los invernaderos, desde el punto de vista de la Agricultura 4.0, controlan factores ambientales ampliándose su temporada de producción con óptimo rendimiento (Pisanu et al., 2020). Los invernaderos son implantados preferentemente en latitudes septentrionales o en zonas geográfica de clima frío, para que la temporada de cosecha se prolongue a lo largo del año. En este sentido, dado que las plantaciones en invernadero se encuentran en zonas interiores bien definidas, la WSN es más fácil de implementar que en cultivos al aire libre.

El sistema de medición desarrollado mide el nivel de intensidad de la señal recibida (RSSI) dentro de un cultivo, específicamente en un invernadero a diferentes distancias y altura entre transmisor y receptor. Con él se recogen datos necesarios para generar nuestro modelo indicado en el capítulo anterior. Está dividido en dos subsistemas. El primero, la estación receptora (figura 4.1a), recoge datos enviados por la estación transmisora en el nodo inalámbrico su-



(a) Nodo sumidero conectado a la Raspberry Pi

(b) Nodo T_x alimentado por una batería de litio externa

Figura 4.1: Nodos WSN al interior de invernadero

midero (nodo R_x), conectado a un ordenador embebido encargado de almacenar valores de potencia en dBm de la señal recibida. El segundo subsistema es la estación transmisora, constituida por el nodo que envía la señal (T_x) (figura 4.1b).

Asimismo, el sistema contribuye a la AP determinando la distancia máxima de comunicación entre dos nodos inalámbricos, planificando el número de nodos en la WSN y su área de cobertura en el despliegue de sensores/actuadores dentro de un campo agrícola. Existen otros estudios sobre este tema, que también emplean redes de sensores inalámbricos, y utilizan dispositivos móviles basados en placas Arduino y módulos de radio Xbee (Shue et al., 2017; Widodo et al., 2017). En nuestro caso, para la medición del RSSI de las ondas de radio, utilizamos una placa que lleva integrado un módulo de radio en la banda ICM de 2,4 GHz (Cama-Pinto et al., 2019). Asimismo, incluimos registro de datos en el propio sistema para que sea autónomo y pueda funcionar 24 horas durante dos semanas sin interrupción con mediciones cada 15 minutos. La principal ventaja del sistema desarrollado es su portabilidad, facilitando la instalación en entorno agrícola y dotando de tiempo de autonomía suficiente para monitorización continua. Por otro lado, nuestro sistema basado en nodos Re-Mote es más compacto que otros sistemas de mayor tamaño con transceptor no integrado, y además el sistema desarrollado tiene precio unitario de aproximadamente 130 €, muy inferior a otras opciones del mercado.

El sistema también es capaz de operar en la banda de 868/915 MHz, aunque durante el

estudio no se realizaron pruebas con ellas. Si el entorno de trabajo en el interior de un invernadero es difícil para el agricultor por tratarse de un ambiente cerrado, normalmente con niveles de temperatura y humedad más elevados que en el exterior, lo es aún más para alguien ajeno a estas tareas, como un investigador que realiza mediciones de ondas de radio durante horas en el interior de un invernadero. En este sentido, la principal diferencia de nuestro sistema propuesto respecto a soluciones similares es su facilidad de despliegue, comprobada en pruebas de campo, y su capacidad de almacenar datos que luego serán utilizados para evaluar el comportamiento de la atenuación de las ondas de radio en un cultivo, con posibilidad de generar nuevos modelos a partir de los valores tomados. Cuanto mayor sea la cantidad de datos recogidos, mayor será la precisión de los resultados obtenidos en el análisis.

4.1.1. Arquitectura del sistema desarrollado

La estación receptora está compuesta por el nodo Re-Mote que se comunica y alimenta a través de su puerto USB conectado a un sistema embebido Raspberry Pi, y éste a su vez a una toma de corriente de 220 V (disponible en el interior del invernadero en nuestros experimentos). El sistema es autónomo, pero también puede visualizarse la toma de datos conectando un ordenador portátil al puerto RJ45 de la Raspberry Pi con cable UTP.

La estación transmisora está formada por el nodo Re-Mote alimentado por batería recargable de iones de litio de 3,7 V con capacidad nominal de 6600 mAh, dotándole de autonomía en su funcionamiento. Estos elementos están alojados en una carcasa de PVC con grado de protección IP65, preparada para mantener aislado su interior de eventuales chorros de agua y polvo. La figura 4.2 muestra esquemáticamente la disposición de dos estaciones en el cultivo. Cada estación consigue estabilidad colocándose sobre un mástil apoyado en una base de 17 kg. Las placas acrílicas que llevan las cajas PVC se fijan a los mástiles.

4.1.2. Hardware del sistema

El sistema de medición y registro desarrollado consta de los siguientes componentes de hardware:

- Nodos Re-Mote. Tienen módulos transceptores de radio capaces de actuar como nodo transmisor T_x y receptor R_x (Zolertia, 2017). Se eligió porque su placa es plataforma IoT con amplio soporte de software Contiki OS, incluyendo 6LoWPAN, RPL y otros




Figura 4.2: Despliegue de las dos estaciones de transmisión y recepción comunicadas inalámbricamente con NLOS en un invernadero de tomate

protocolos IoT ampliamente utilizados. Integra el chip System-on-Chip (SoC) CC2538 de Texas Instruments (Instruments, 2015) para comunicaciones de bajo consumo y corto alcance en la banda de 2.4 GHz. El consumo de corriente es 24 mA al transmitir, 20 mA al recibir y 1,3 uA en estado de reposo (Bezuntea et al., 2018; Instruments, 2015; Van Herbruggen et al., 2019). Por otro lado, el EIRP del nodo T_x fue de -29 dBm en las pruebas y se utilizaron antenas con 5 dBi de ganancia en ambas motas. La sensibilidad de recepción en los nodos Re-Mote fue de -100 dBm.

- Raspberry Pi. Servidor que almacena la datos de las mediciones en memoria SD con formato CSV (figura 4.2). Además, alimenta y comunica al R_x -mote a través de su puerto USB.
- Batería de iones de litio. Entrega energía al nodo T_x -mote asegurando su funcionamiento sin depender de conexión a toma de corriente eléctrica externa.
- Sensor de humedad y temperatura. El sensor DHT22 está conectado al módulo transmisor que envía datos de temperatura y humedad, medidas tradicionalmente utilizadas para controlar y supervisar condiciones ambientales del cultivo en invernaderos.

4.1.3. Software del sistema

Para el correcto funcionamiento del sistema, es necesario minimizar el consumo de energía implementando una adecuada infraestructura de software. A continuación se especifica el software usado en cada caso.

- **Nodos Re-Mote.** El sistema operativo Contiki, desarrollado en 2002 por Adam Dunkels, se ha instalado y configurado como entorno de ejecución de código abierto para nodos sensores inalámbricos de baja potencia y memoria limitada (Dunkels, 2013). Es ligero, haciéndolo ideal para soluciones IoT. Sus aplicaciones se desarrollan con lenguaje de programación C. Tiene una implementación TCP/IP integrada para dispositivos embebidos, soportando oficialmente varias plataformas de dispositivos que conforman la WSN, incluyendo la placa Re-Mote (Dunkels et al., 2004; Staudemeyer et al., 2019). En el nodo T_x se utilizó el módulo de ahorro de energía de Contiki (`power-mgmt.h`), ya que durante la fase de pruebas esta estación se encuentra alejada del nodo receptor y no dispone de una toma de corriente, siendo alimentada por su propia batería. Para comunicación por radio, empleamos la pila Rime (`rime.h`) que proporciona un conjunto de primitivas de comunicación básicas para difusión en red de un solo salto (“unicast”) en el mejor de los casos y para difusión fiable de varios saltos (“multi-hop unicast”) (Dunkels et al., 2007).
- El programa desarrollado en C para la estación T_x envía tramas de datos de temperatura y humedad obtenidas del sensor DHT22 periódicamente, permaneciendo en estado de reposo el resto del tiempo. Esto reduce el consumo de energía, ampliando la autonomía del transmisor. Por otro lado, la estación R_x mide RSSI y recibe la trama de datos enviada por el nodo T_x .
- **Raspberry Pi.** Se ha instalado la distribución Linux Raspbian basada en Debian y se han desarrollado varios scripts en lenguaje Python que establecen comunicación serial con dispositivos Zolertia y generan archivos .csv a partir de los datos que recibe, almacenándolos en la memoria SD de la Raspberry Pi. También dispone de un módulo de reloj con pila CR2032 para que la fecha y hora no se descalibren cuando se apague, grabándose con cada registro de RSSI.

4.2. Procedimiento de medición y pruebas de campo en 2018


Las pruebas de comunicación se realizaron utilizando el sistema de medición desarrollado (figura 4.3a) en febrero del 2018 en el interior de cuatro invernaderos de tomate con áreas de 10 000 m² cada uno, cuya producción es comercializada al mercado europeo. Dichos invernaderos están situados en la Cañada de San Urbano, provincia de Almería, comunidad

autónoma de Andalucía en España.

La distribución de la plantación del invernadero de tomate tiene pasillos de 1,2m (figura 4.3b), 50 cm de distancia entre el tallo de cada planta (figura 4.3c), con separación de las líneas pareadas y extremos de los follajes de 60 y 100 cm respectivamente (figura 4.3d), y longitud de nave principal de 100 m (figura 4.3e).



(a) Nodo de sensores




(b) Dimensiones del pasillo



(c) Distancia entre cordeles



(d) Separación de las líneas emparejadas



(e) Medición del pasillo principal

Figura 4.3: Vista interior de invernadero de tomates en Almería

Los valores experimentales se registran a intervalos de 10s durante 10 minutos en cada posición. La altura de los nodos fue la misma para el nodo T_x y R_x en cada etapa de la medición. Además de las pruebas de registro y análisis de RSSI, también se pueden realizar funciones de monitorización de variables agrícolas y ambientales conectando al Re-Mote sensores analógicos y digitales, por ejemplo, de humedad o temperatura.

Los valores RSSI registrados pueden tomarse en diferentes etapas del cultivo, desde la plantación hasta la cosecha, si se desea analizar datos y/o construir un modelo que relacione la atenuación de ondas de radio con etapas de crecimiento de la plantación. Alternativamente, el análisis o generación de un modelo puede desarrollarse a partir de la información registrada, cuando los datos se toman en caso extremo, es decir, cerca del momento de la cosecha, cuando el grosor del dosel es máximo.

En la figura 4.4 resumimos las etapas del estudio de la atenuación de ondas de radio basado en RSSI:

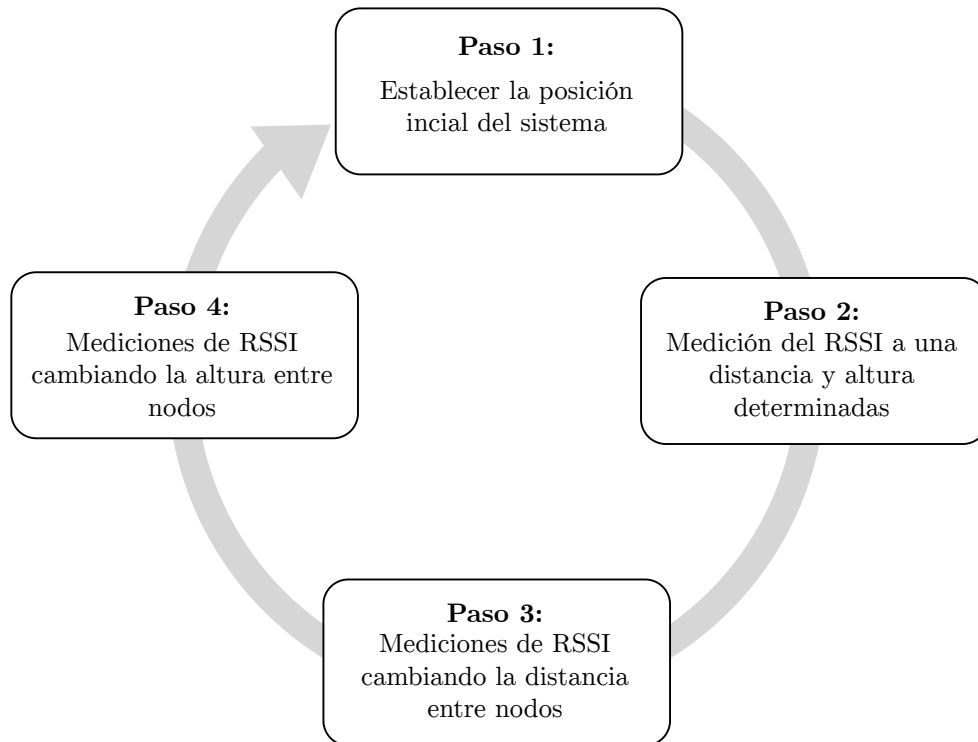



Figura 4.4: Pasos para realizar estudio de atenuación radioeléctrica basado en el RSSI dentro de un invernadero.

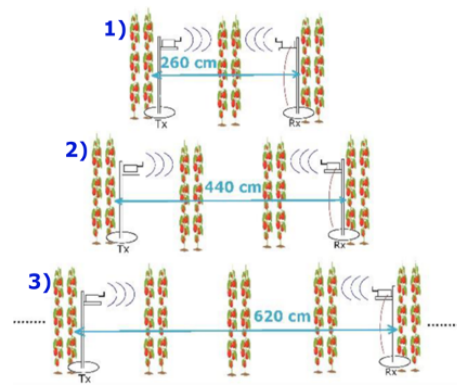
Paso 1: Posición inicial del sistema. La posición de la estación receptora (R_x) es fija, ya que se alimenta de corriente eléctrica de 220 V procedente de una toma de corriente del

invernadero. La estación R_x es el nodo de referencia donde se mide RSSI. Por ejemplo, en la figura 4.5a se muestran en rojo las posiciones de los nodos receptores (A_1, A_2, A_3, A_4) en un extremo del invernadero durante la medición de RSSI.

Paso 2: Medición del RSSI a una distancia y altura determinadas. En este caso, la estación transmisora (T_x) se coloca en una posición específica con respecto al nodo R_x . Según la figura 4.3a, el nodo R_x se fijó inicialmente en la posición A_1 mientras que el nodo T_x se colocó en la posición B_1 con una distancia específica de 260 cm. Esta distancia depende de la hilera de plantas y espacio entre los raíles del invernadero. En este caso, sólo hay una fila de plantas espaciadas entre sí. Además de la distancia, ambos nodos deben estar situados a la misma altura, como se muestra en la figura 4.5b.



(a) Marco de plantación dentro del invernadero con nodo T_x (azul claro) cambia la distancia con respecto al nodo R_x (rojo)



(b) La altura de ambos nodos se mantuvo constante mientras cambiaba la distancia entre ellos

Figura 4.5: (a) Marco de plantación dentro de invernadero (b) altura entre nodos

Una vez fijadas la distancia y altura para ambos nodos, el nodo R_x realiza mediciones RSSI y recoge al mismo tiempo valores de temperatura y humedad registradas por el nodo T_x para transmitirlos posteriormente al nodo R_x . Estas mediciones pueden realizarse a intervalos de tiempo personalizable y pueden almacenarse como una trama de datos.

Posteriormente, ambas estaciones se desplazan hacia la derecha (por ejemplo, A_2 y B_2 a A_3 y B_3 respectivamente en la figura 4.5a) manteniendo la misma altura y distancia entre ellas. El nodo R_x realiza nuevas mediciones de RSSI a una velocidad constante, generando nueva trama de datos. El proceso (movimiento y medición del nodo) se reiteró hasta alcanzar las ubicaciones A_4 y B_4 . Las mediciones repetidas a la misma

distancia y altura en diferentes posiciones garantizan que la medición de RSSI tenga en cuenta fluctuaciones que se producen por la presencia de ramas frondosas, las hojas y frutos de cultivos.

Una colección de datos de todas estas mediciones en diferentes posiciones (A_1, A_2, A_3, A_4) se almacena en la Raspberry PI del nodo R_x .

Paso 3: Mediciones de RSSI modificando distancia. En este caso, las dos estaciones se alejan una de otra, cambiando distancia entre ellas. Por ejemplo, en la figura 4.5b vemos que después de medir RSSI en la posición B, movemos la estación T_x a la posición C a 440 cm de distancia, que corresponde a la distancia entre dos filas de plantas entre la estación T_x y R_x . La estación T_x se colocó en posiciones C_1, C_2, C_3, C_4 , y el RSSI se midió y registró con la estación R_x en posiciones A_1, A_2, A_3, A_4 respectivamente. Por otro lado, vemos en la figura 4.5b que la altura fue la misma durante las mediciones de RSSI.

Paso 4: Mediciones de RSSI modificando altura. En este caso, las dos estaciones cambiaron sus alturas a un nuevo valor, luego se repite el procedimiento de medición a diferentes distancias. Después que la estación T_x llegue al extremo opuesto del invernadero, se repite el procedimiento cambiando altura de ambos nodos a una nueva, por ejemplo, 50 cm sobre el suelo. A continuación, se repiten los pasos a partir del paso primero.

En la figura 4.6 se muestra la medición de la potencia recibida obtenida con línea de vista ($P_{rx-fspl}$), donde la atenuación de la señal recibida es causada sólo por L_{fspl} .

4.3. Pruebas de campo realizadas en el año 2020

Nuestros ensayos de campo se realizaron el mes de febrero del 2020 en cuatro invernaderos de tomate con dimensiones de 10 000 m², en terreno llano, en distintas localidades de Almería: (a) La Cañada - 8 m s n m, (b) Retamar - 12 m s n m, (c) El Alquian - 42 m s n m, (d) Níjar - 248 m s n m, donde msnm significa metros sobre el nivel del mar. Por tanto, como se puede observar, todos ellos están próximos al mar de Alborán, a excepción del situado en Níjar el más cercano a la montaña. Los invernaderos son distintos en ubicación geográfica y ligeramente diferente en distribución interna a los del año 2018, y tienen características similares a la figura 4.7.

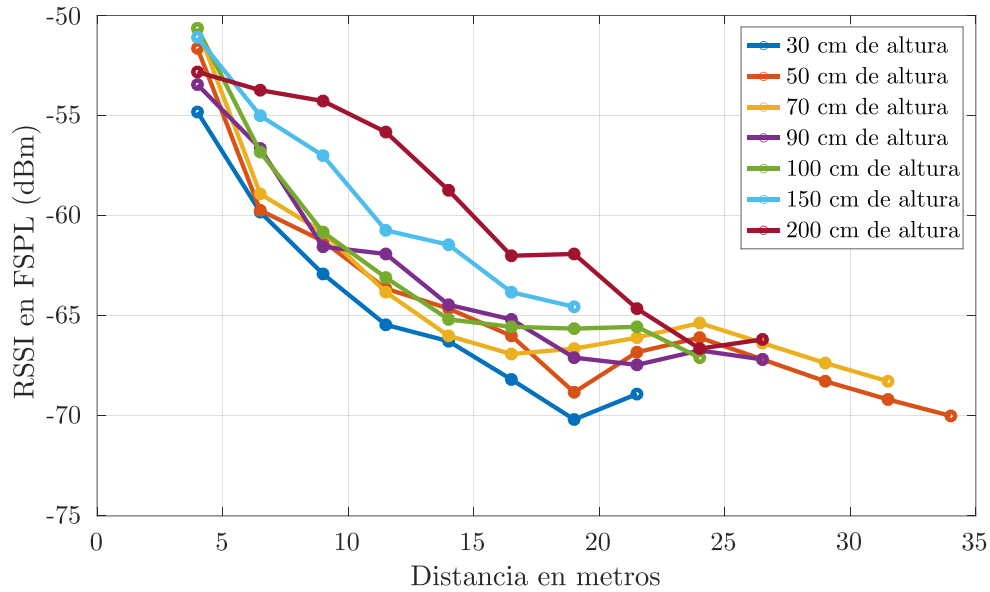


Figura 4.6: Media del nivel de la señal recibida en dBm de las cuatro ubicaciones, con línea de visión (LOS) entre nodos T_x y R_x a diferentes alturas del suelo (30 cm, 50 cm, 70 cm, 90 cm, 100 cm, 150 cm).

En contraste a las mediciones del año 2018, el nodo sumidero R_x recibe el valor de la señal atenuada enviada por el nodo T_x cada 5 minutos, y se repite la medición 10 veces. Los pasos a seguir en la medición del año 2020 son los mismos que en el año 2018, y en la figura 4.7 se muestra la ligera diferencia en medidas de los pasadizos internos de los invernaderos. Además, como se muestra en la figura 4.7a entre los nodos T_x y R_x existe un muro de tomatera que bloquea la señal.

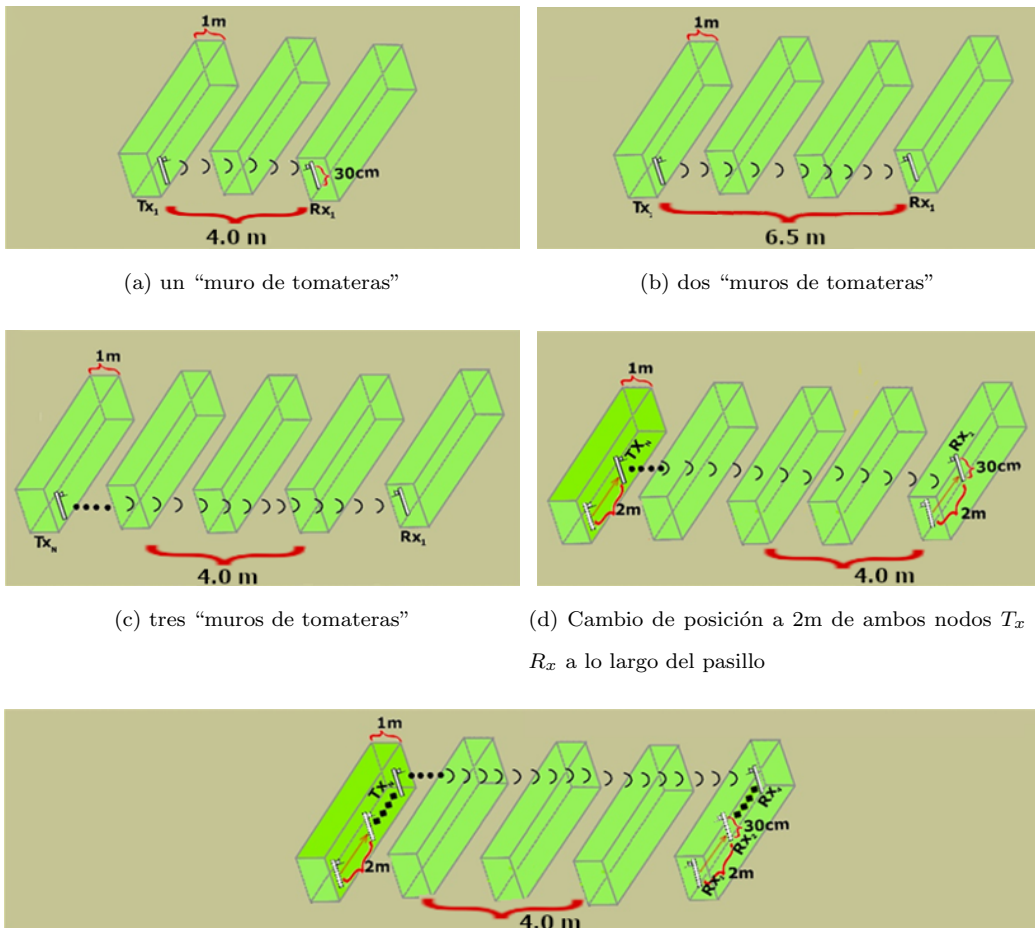
A continuación, el nodo sumidero permanece en su misma posición R_{x1} , mientras el nodo T_x , se aleja en línea recta hasta dos paredes de tomatera en la posición T_{x2} , como se puede observar en la figura 4.7b, aumentando así sucesivamente el número de “paredes de tomatera” hasta la posición final: T_{xn} , mientras aumenta la distancia y la atenuación entre ambos nodos (T_x y R_x) (Ver figura 4.7c).

Al llegar al límite de cobertura entre los nodos T_x y R_x , se reinicia el proceso desplazándolos 2 metros a lo largo de la “pared de tomate” con el nodo R_x ahora en posición R_{x2} como se muestra en la figura 4.7d. Repetimos los pasos anteriores, de modo que el nodo sumidero llamado “ R_{x1} ” se desplaza hasta “ R_{x4} ” pasando previamente por posiciones “ R_{x2} ” y “ R_{x3} ”, y recibiendo la señal atenuada enviada por los nodos transmisores de T_{x1} a T_{xn} , tal como se indica en la figura 4.7e. Se registran 160 valores de RSSI para cada distancia específica entre nodos T_x y R_x porque 10 son los valores en cada posición del nodo receptor R_{x1} , R_{x2} , R_{x3} ,

R_{x4} , duplicando este proceso en 4 invernaderos diferentes. Finalmente, los valores recogidos se promedian.

Reproducimos los pasos anteriores para nuevas alturas. Concretamente, la comunicación entre nodos se evalúa con altura de sus antenas a 30 cm, 50 cm, 70 cm, 90 cm, 100 cm, 150 cm y 200 cm.

Las mediciones de las potencias recibidas en el nodo receptor (R_x), atenuadas por la presencia de vegetación es $P_{rx_follaje}$. Estos valores se registran según los pasos de despliegue mostrados en la figura 4.7, y se muestran en el gráfico de curvas de la figura 4.8. En ella se observa mayor cobertura entre nodos T_x y R_x cuando las alturas de antenas en los nodos están a 50 cm del suelo, con una distancia máxima entre ellos de 35 m.



(a) un “muro de tomates”

(b) dos “muros de tomates”

(c) tres “muros de tomates”

(d) Cambio de posición a 2m de ambos nodos T_x y R_x a lo largo del pasillo

(e) Cambio hasta 4 posiciones a lo largo de cada pasillo de los nodos T_x ($T_{x1}, T_{x2}, T_{x3}, T_{x4}$) y R_x ($R_{x1}, R_{x2}, R_{x3}, R_{x4}$)

Figura 4.7: Disposición del enlace inalámbrico entre nodos T_x y R_x dentro del invernadero respecto al número de “muro de tomates”.

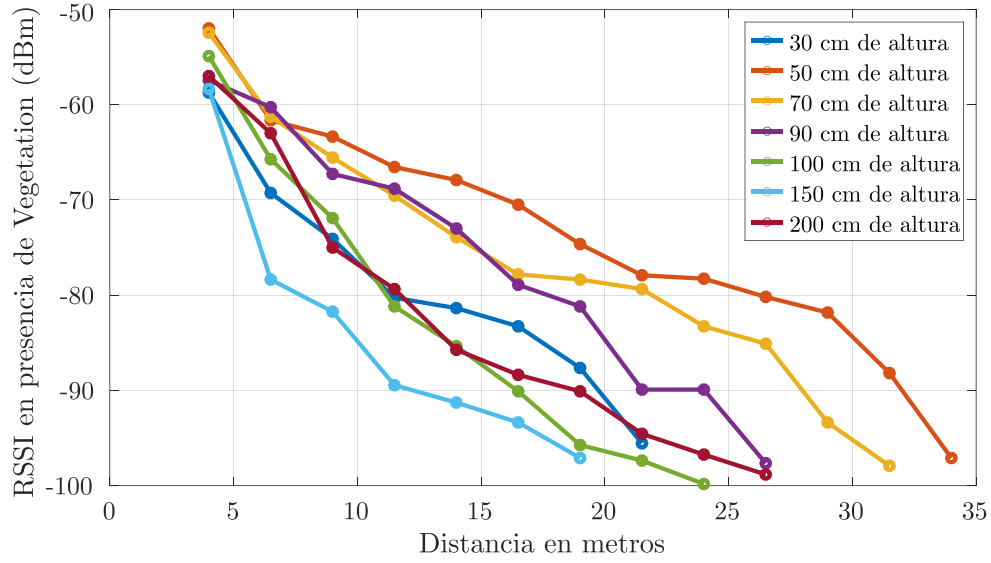


Figura 4.8: Promedio del nivel de la señal recibida en dBm de las cuatro ubicaciones, con línea de visión obstruida por paredes de tomates entre nodos T_x y R_x a diferentes alturas del suelo (30 cm, 50 cm, 70 cm, 90 cm, 100 cm, 150 cm)

La figura 4.9 representa la atenuación por presencia de vegetación ($L_{follaje}$), correspondiente a la ecuación 4.1.

$$L_{follaje} (dB) = P_{rx_follaje} (dBm) - P_{rx_fspl}(dBm) \quad (4.1)$$

La curva de atenuación del follaje ($L_{follaje}$) a 50 cm del suelo puede compararse con los modelos empíricos de Weissberger, ITU-R, FITU-R y COST235 como se muestra en la figura 4.10. Ninguno de ellos se asemeja al valor obtenido empíricamente surgiendo la necesidad de encontrar un nuevo modelo, objetivo de nuestra investigación.




Figura 4.9: Media de atenuación en cuatro invernaderos por presencia de vegetación entre nodos T_x y R_x a diferentes alturas del suelo (30 cm, 50 cm, 70 cm, 90 cm, 100 cm, 150 cm). El eje de abscisas indica profundidad del espesor de la vegetación en tramos que aumentan en un metro, el ancho de la pared de cada “muro de tomates”.

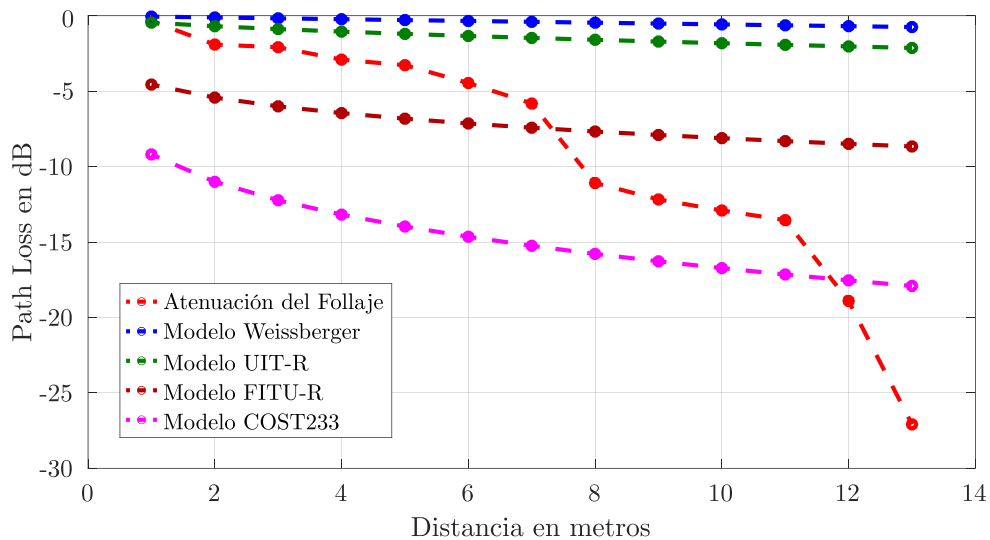


Figura 4.10: Media de atenuación por presencia de follaje en (dB) de cuatro localizaciones a 50 cm del suelo frente a modelos empíricos (Weissberger, UIT, FITU-R, COST235).

4.4. Conjunto de datos de atenuación de ondas de radio en invernadero de tomates

A continuación, y con el fin de validar el sistema de medición, así como el procedimiento de medición, mostramos la recolección de información de la atenuación de ondas de radio basado en RSSI, concretamente en un invernadero de tomate de la Cañada. La figura 4.11a muestra la ubicación en el mapa de España, y la figura 4.11b muestra la imagen por satélite de una parte de los invernaderos en Almería.

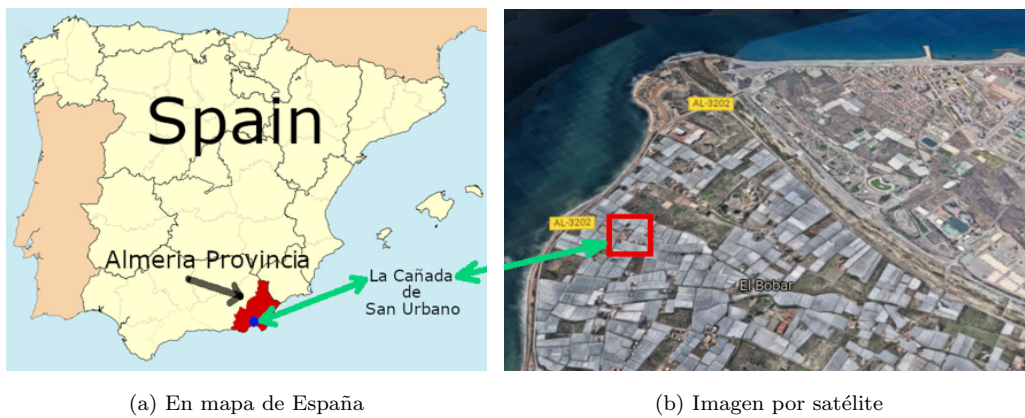


Figura 4.11: Ubicación del invernadero en la Cañada de San Urbano en la provincia de Almería

En este caso, las mediciones de RSSI fueron obtenidas por el nodo receptor a diferentes distancias (260, 440, 620, 800, 980, 1160, 1340, 1520, 1700, 1880, 2060, 2240 y 2420 cm) con diferentes alturas (30, 50, 70, 90, 100, 150 y 200 cm). Inicialmente, el nodo receptor colocado a 5 cm del nodo transmisor mide un valor RSSI de -24 dBm (mejor intensidad de señal); éste fue el valor de referencia RSSI utilizado para determinar la atenuación de ondas de radio cuando el nodo T_x se aleja del R_x .

El registro de todas las mediciones se guardó en una base de datos. Las mediciones RSSI en una posición específica (por ejemplo, A_1 - figura 4.5a) correspondientes a un marco de datos se tomaron cada 10 s y se almacenan en formato CSV dentro de la memoria SD de la Raspberry Pi. Los otros datos de diferentes posiciones a igual distancia y altura se almacenan en el mismo archivo. Cada registro de datos incluye en su primera columna el número de muestra, a continuación el valor de temperatura en grados Celsius, la humedad relativa, el RSSI en dBm, y finalmente la fecha y la hora de la muestra. En la tabla 4.1 se puede observar una muestra del fichero almacenado. Este conjunto de datos completo puede encontrarse en

el siguiente enlace (Cama-Pinto et al., 2021b).

Los nombres de los archivos indican primero la altura de las antenas de los nodos y luego la distancia entre ellos. Por ejemplo, el archivo “50-1880.csv” incluye registro de las mediciones con antenas de nodos a 50 cm y distancia de 1880 cm entre ellas. En cada archivo hay 4 segmentos correspondientes al cambio de posiciones de los nodos T_x y R_x , por ejemplo, A_1 con B_1 , A_2 con B_2 , A_3 con B_3 y A_4 con B_4 , como se muestra en la figura 4.5a.

Tabla 4.1: Conjunto de datos recolectado con sistema RSSI

Ciclo	Temp (°C)	Hum (%)	RSSI (dBm)	Fecha	Hora
1	14	63	-93	25 de Marzo del 2018	11:37:48
2	14	63	-93	25 de Marzo del 2018	11:37:58
3	14	63	-93	25 de Marzo del 2018	11:38:08
4	14	63	-93	25 de Marzo del 2018	11:38:18
5	14	63	-93	25 de Marzo del 2018	11:38:28
6	14	63	-94	25 de Marzo del 2018	11:38:38
7	14	63	-94	25 de Marzo del 2018	11:38:48
8	14	63	-94	25 de Marzo del 2018	11:38:58
9	14	63	-94	25 de Marzo del 2018	11:39:08
10	14	63	-93	25 de Marzo del 2018	11:39:18
11	14	63	-93	25 de Marzo del 2018	11:39:28
12	14	63	-93	25 de Marzo del 2018	11:39:38
13	14	63	-93	25 de Marzo del 2018	11:39:48
14	14	63	-92	25 de Marzo del 2018	11:39:58
15	14	63	-91	25 de Marzo del 2018	11:40:08
16	14	63	-91	25 de Marzo del 2018	11:40:18
17	14	63	-91	25 de Marzo del 2018	11:40:28
18	14	63	-91	25 de Marzo del 2018	11:40:38
19	14	63	-91	25 de Marzo del 2018	11:40:48
20	14	63	-91	25 de Marzo del 2018	11:40:58
21	14	63	-91	25 de Marzo del 2018	11:41:08
22	14	63	-91	25 de Marzo del 2018	11:41:18
23	14	63	-91	25 de Marzo del 2018	11:41:28
24	14	63	-91	25 de Marzo del 2018	11:41:38
25	14	63	-91	25 de Marzo del 2018	11:41:48

El módulo de ahorro de energía `power-mgmt.h` se usa en el código cargado en los nodos Zolertia Re-Mote, permitiendo que la batería pasara de 3,7 V (nodo T_x) a 2,8 V en 60 horas de uso, en tomas de cada muestra de 10 s. Por debajo de 28 V es aconsejable no realizar mediciones porque valores registrados por los sensores pueden contener errores.

Capítulo 5

Determinación del modelo empírico de atenuación en invernaderos

A través de pruebas de campo en los capítulos anteriores se establece que la altura de las antenas más favorables para conseguir la mayor cobertura entre nodos T_x y R_x es de 50 cm medidos desde la superficie. A continuación determinamos dos modelos empíricos que predicen la atenuación de ondas de radio a su paso por el follaje en la banda de 2,4 GHz usando métodos de Regresión Regularizada y Deep Learning.

5.1. Determinación del modelo empírico usando método de Regresión Regularizada

Con el fin de reducir el número de parámetros de la ecuación 3.9, identificamos previamente cuál de ellos son los relevantes para prescindir del resto en el modelo. Estos parámetros son llamados “parámetros de importancia proyectados” (PIP) y estiman su contribución individual al modelo si poseen valor superior a 0,03. Observando la figura 5.1 notamos que algunos parámetros apenas contribuyen a la función $L_{follaje}$. Estos son θ_8 , θ_9 , θ_{10} , θ_{17} y θ_{19} (los últimos de la figura y tabla).

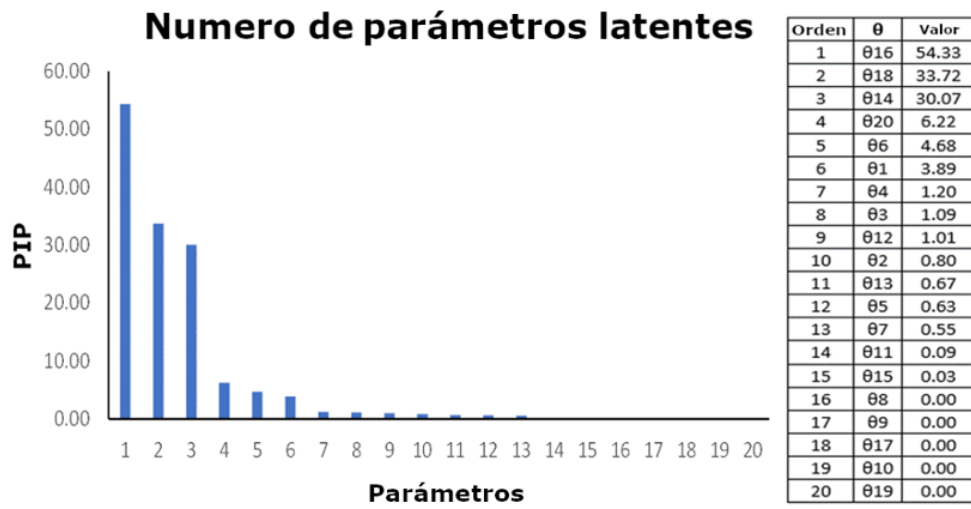


Figura 5.1: Valores PIP para el modelo elegido. Los parámetros θ_8 , θ_9 , θ_{10} , θ_{17} , y θ_{19} se excluyen del modelo por tener valores inferiores a 0,03

En la figura 5.2 la ecuación multiparamétrica se ha reducido utilizando parámetros PIP mayores a 0,03. Al aplicar RMSECV en el modelo validamos que no hay pérdida de información en la ecuación reducida.

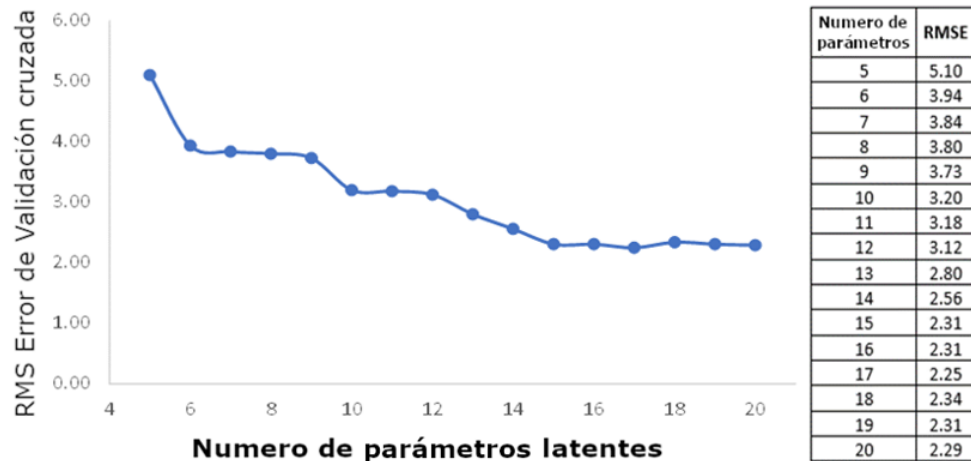



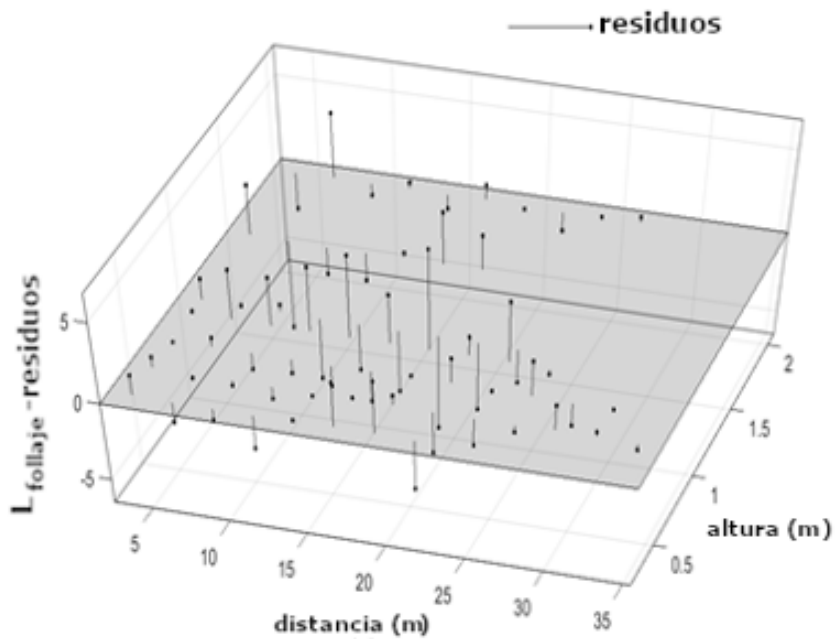
Figura 5.2: RMSECV en función del número de parámetros utilizados en el modelo $L_{follaje}$

La figura 5.3 muestra la solución obtenida para el conjunto de 20 parámetros, con vista en 3D de la Ecuación 3.6 (figura 5.3a), siendo el eje x para la variable distancia (d), y el eje y para la variable altura (h), ambas en metros. El eje z evalúa la función $L_{follaje}(d, h)$ para cada valor de distancia y altura. Los puntos negros son valores medidos en el invernadero.

La figura 5.3b muestra valores residuales entre datos medidos y predichos. En la tabla 5.1 se muestran los valores de los parámetros optimizados.



(a) Valores medidos representados por puntos negros junto con modelo optimizado de $L_{follaje}(d, h)$ para 20 parámetros



(b) Valores residuales de $L_{follaje}(d, h)$ determinados como diferencia entre datos medidos y predichos

Figura 5.3: Solución obtenida para el conjunto de 20 parámetros

Los evaluación de la función multiparamétrica optimizada es usando los métodos descritos en el capítulo 3, mostrados en columnas de la tabla 5.2. Resaltamos que AIC y SBC son índices comparativos que deben contrastarse con otros modelos comprobando que no haya pérdida de información en la estimación. El modelo se valida mediante prueba de permutación.

5.1. MODELO EMPÍRICO USANDO MÉTODO DE REGRESIÓN REGULARIZADA

Tabla 5.1: Valores de parámetros optimizados utilizando función de coste de la ecuación 3.7. Algunos parámetros, como puede verse, tienen valores cercanos a cero.

θ	1	2	3	4	5	6	7	8	9	10
Valor	3,89	-0,80	1,09	-1,20	-0,63	-4,68	0,55	0,00	0,00	0,00
θ	11	12	13	14	15	16	17	18	19	20
Valor	-0,09	1,01	0,67	30,07	-0,03	-54,33	0,00	33,72	0,00	-6,22

Tabla 5.2: Parámetros de evaluación de la optimización regularizada con 20 parámetros.

	N° Parametros	R^2	R^2 Adj.	MSE	RMSE	MAPE	AIC	SBC
$L_{follaje}(d, h)$	20	0,948	0,946	5,27	2,29	0,167	410	199

Finalmente la ecuación 3.9 se reduce en la ecuación 5.1:

$$\begin{aligned}
 L_{follaje}(d, h) = & \theta_1 + \theta_2 d^{\theta_3} h^{\theta_4} + \theta_5 d^2 h + \theta_6 d h^2 + \theta_7 d^2 h^2 + \theta_{11} d^2 h^3 \\
 & + \theta_{12} d h^3 + \theta_{13} d^2 + \theta_{14} h^2 + \theta_{15} d^3 + \theta_{16} h^3 + \theta_{18} h^4 \\
 & + \theta_{20} h^5
 \end{aligned} \tag{5.1}$$

Agrupando términos obtenemos la ecuación 5.2:


$$L_{follaje}(d, h) = \theta_2 d^{\theta_3} h^{\theta_4} + f_{\text{compensación}} \tag{5.2}$$

Y el contenido de $f_{\text{compensación}}$ en la ecuación 5.3:


$$\begin{aligned}
 f_{\text{compensación}} = & \theta_1 + \theta_5 d^2 h + \theta_6 d h^2 + \theta_7 d^2 h^2 + \theta_{11} d^2 h^3 + \theta_{12} d h^3 \\
 & + \theta_{13} d^2 + \theta_{14} h^2 + \theta_{15} d^3 + \theta_{16} h^3 + \theta_{18} h^4 + \theta_{20} h^5
 \end{aligned} \tag{5.3}$$

La ecuación 5.2 tiene un primer término equivalente al modelo de atenuación dado por Weissberger y un segundo término $f_{\text{compensación}}$ que es la compensación al modelo de Weissberger a añadir para estimar $L_{follaje}$. A partir de las figuras 5.1 y 5.2, los parámetros $\theta_5, \theta_7, \theta_{11}, \theta_{13}, \theta_{15}$ de la ecuación 5.1 podrían ser ignorados en el modelo debido a su ligero RMSE, significando que el modelo no depende de la distancia al variar la altura. Sin embargo, sólo anulamos aquellos parámetros que tienen valor aproximado a cero, estos parámetros son $\theta_8, \theta_9, \theta_{10}, \theta_{17},$ y θ_{19} . La aplicación de la función paramétrica se aplica para ajustar valores experimentales obtenidos por la ecuación 4.1. Los parámetros de la ecuación 5.1 se ajustan mediante la función de coste $J(\theta)$, ecuación 3.7. Como se explicó en el capítulo 3, para conseguirlo se aplica el algoritmo de optimización (basado en el método simplex de Nelder-Mead).

La figura 5.4 muestra en este caso la solución obtenida para el conjunto de 15 parámetros. Esta figura (5.4a) muestra una vista en 3D de la ecuación 3.6, donde el eje x es la variable distancia (d) y el eje y la variable altura (h), ambas en metros. El eje z son valores cuando se evalúa la función $L_{follaje}(d, h)$ para cada valor de distancia y altura. Los puntos negros son los valores medidos en el invernadero. La figura 5.3b muestra valores residuales entre datos medidos y predichos. En la tabla 5.3 se observan los valores de los parámetros optimizados.



(a) Valores medidos representados por puntos negros junto con modelo optimizado de $L_{follaje}(d, h)$ para 15 parámetros



(b) Valores residuales de $L_{follaje}(d, h)$ determinados como diferencia entre datos medidos y predichos

Figura 5.4: Solución obtenida para el conjunto de 15 parámetros

La calidad de este nuevo modelo está expresada mediante validación cruzada de los paráme-

tros R^2 y Q^2 para así poder compararlo con el modelo anterior. El RMSECV obtenido es 2,40. El modelo también se ha validado mediante prueba de permutación.

Tabla 5.3: Valores de parámetros optimizados utilizando la función de coste de la ecuación 3.7

θ	1	2	3	4	5	6	7	
Valor	-6,73	-0,08	1,62	-1,59	-0,57	-3,33	0,49	
θ	11	12	13	14	15	16	18	20
Valor	-0,12	1,10	0,30	100,59	0,00	-167,33	95,02	-17,69

Al igual que en el modelo anterior, se valida con el MSE, RMSE, MAPE, AIC, SBC. Los valores de evaluación de la función multiparamétrica optimizada se muestran en la tabla 5.4.

Tabla 5.4: Evaluación de parámetros en optimización regularizada con 15 parámetros.

	N° Parametros	R^2	R^2 Adj.	MSE	RMSE	MAPE	AIC	SBC
$L_{follaje}(d, h)$	15	0,942	0,940	5,80	2,40	0,189	417	206

Los resultados de los modelos de atenuación de las ondas de radio en un invernadero de tomates desarrollados en esta investigación son muy similares. Los R^2 para ambos son de sólo 0,004, estableciéndose que la correlación entre el modelo y datos obtenidos es de 0,942 para el primero y de 0,946 para el segundo modelo. Asimismo, el R^2 ajustado, en ambos casos, es muy similar, difiriendo sólo en 0,006. Los valores de MSE y RMSE apenas muestran diferencias significativas. El AIC y el SBC pertenecen al mismo orden de magnitud, deduciendo que no hay pérdida de información al aplicar uno u otro modelo.

Tanto los modelos de 15 como de 20 parámetros son válidos. En ambos casos se obtienen buenos indicadores de evaluación, pudiendo utilizarse cualquiera de ellos. Sin embargo, el modelo de 15 parámetros tiene una ventaja sobre el de 20 parámetros. Esta ventaja consiste en su simplicidad usando cinco parámetros menos que el modelo de 20 parámetros (véase tabla 5.5).

Tabla 5.5: Comparación entre evaluación de parámetros en optimizaciones regularizadas para modelos de 15 y 20 parámetros.

	N° Parametros	R^2	R^2 Adj.	MSE	RMSE	MAPE	AIC	SBC
$L_{follaje}(d, h)$	15	0,942	0,940	5,80	2,40	0,189	417	206
$L_{follaje}(d, h)$	20	0,948	0,946	5,27	2,29	0,167	410	199

5.2. Determinación del modelo empírico usando Deep Learning

La figura 5.5 muestra la solución obtenida para el modelo de aprendizaje profundo propuesto. Esta figura muestra una vista en 3D de la red neuronal mostrada en la Figura 3.3 (figura 5.5a), donde el eje x es la variable distancia (d) y el eje y es la variable altura (h), ambas en metros. El eje z son los valores al evaluar la red neuronal profunda $L_{foliage}(d, h)$ para cada valor de distancia y altura. Los puntos azules son los valores medidos en el invernadero. La figura 5.5b muestra los valores residuales entre los datos medidos y los calculados con la red neuronal profunda.

La calidad de este nuevo modelo se expresa mediante la validación cruzada de los parámetros, R^2 y Q^2 , que son 0,966 y 0,957 respectivamente. Mientras que el RMSECV es de 1,98. La red neuronal profunda también se ha validado mediante la prueba de permutación.


Para este modelo también hemos calculado el error cuadrático medio (MSE), el error cuadrático medio (RMSE) y el error porcentual medio absoluto (MAPE).

Además, se proporciona el criterio de información de Akaike (AIC) y el criterio de información de Schwarz (SBC), que indican un buen ajuste con los parámetros estimados. Los valores de evaluación de la función multiparamétrica optimizada se muestran en la tabla 5.6. El valor R^2 ajustado es de 0,964.


Tabla 5.6: Evaluación de la calidad estadística del modelo de aprendizaje profundo propuesto.

	R^2	R^2 Adj.	MSE	RMSE	MAPE	AIC	SBC
$L_{foliage}(d, h)$	0,966	0,964	3,39	1,98	0,113	432	221

La atenuación de las ondas de radio del aprendizaje profundo para la vegetación en un invernadero de tomates desarrollado en esta investigación mejora las predicciones de otros modelos, el R^2 es de 0,966. Asimismo, el R^2 ajustado en ambos casos es muy similar, cerca de 0,964. Los valores de MSE y RMSE están cercanos en valor, lo que significa que el modelo de aprendizaje profundo tiene un buen ajuste. El AIC y el SBC son del mismo orden de magnitud, por lo que se deduce que no hay pérdida de información al aplicar uno u otro modelo.



(a) Valores medidos representados por puntos negros junto con el $L_{foliage}(d, h)$ optimizado para el modelo de aprendizaje profundo propuesto.



(b) Valores residuales de $L_{foliage}(d, h)$ determinados como diferencia entre los datos medidos y los predichos.

Figura 5.5: Solución obtenida para el modelo de aprendizaje profundo

Capítulo 6

Validación del modelo teórico de atenuación en invernaderos de tomates

En este capítulo analizamos que tan cercanos son los valores que entregan los modelos obtenidos respecto a los datos reales.

6.1. Datos de pruebas de campo recolectados en el año 2018 comparados con modelos empíricos

Los valores promedio de RSSI entre nodos T_x y R_x con NLOS registrados en el interior de los invernaderos de tomate están reflejados en la figura 6.1. El mayor alcance registrado entre nodo T_x y R_x se da cuando la alturas de ambas antenas son 50 cm y arroja el menor valor con 150 cm.

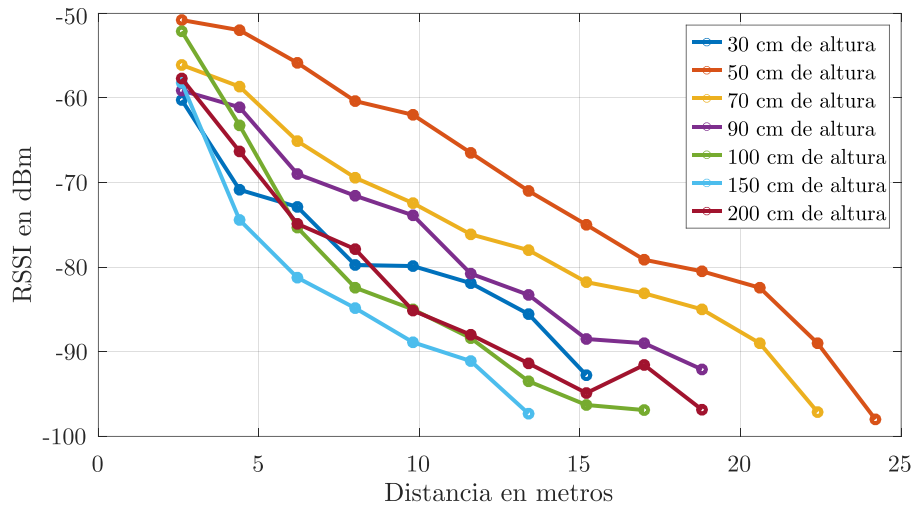


Figura 6.1: Nivel de señal en dBm y cobertura máxima entre el nodo T_x y R_x a diferentes alturas con respecto al suelo (30 cm, 50 cm, 70 cm, 90 cm, 100 cm, 150 cm y 200 cm)

A partir de las mediciones realizadas a diferentes distancias y alturas, se analiza el valor medio de RSSI y se estudia cómo se atenúan las señales de ondas de radio a 2400 MHz a su paso por las hileras de tomatas. En la figura 6.1, se observa que a 50 cm del suelo la distancia máxima entre la comunicación de los dos nodos T_x y R_x es de 2420 cm, mientras que la distancia mínima de cobertura entre ellos, 1340 cm, se alcanza cuando los nodos se sitúan a 150 cm del suelo. Los valores se registraron en el nodo R_x hasta que alcanzaron -100 dBm, ya que la sensibilidad del receptor es el mismo. Sin embargo, a efectos de estabilidad del enlace inalámbrico, se sugiere tener un margen entre la potencia detectada por el receptor y la sensibilidad de recepción igual o superior a 10 dB (Zennaro et al., 2010).

La figura 6.2 muestra las curvas de atenuación de ondas de radio entre nodos T_x y R_x a 50 y 150 cm del suelo. Por ejemplo, el valor medio de RSSI a 260 cm de distancia entre dos nodos y a 150 cm del suelo es de $-58,22$ dBm. La atenuación del trayecto se obtiene con el siguiente cálculo $EIRP + \text{Atenuación del camino} + G_{r_x} = -58,22 \text{ dBm}$. Por tanto,

$$\text{Atenuación trayecto (PathLoss)} = -58,22 \text{ dBm} + 29 \text{ dBm} - 5 \text{ dB} = -34,22 \text{ dB}$$

Es decir, la atenuación producida durante el trayecto de la onda de radio entre el nodo T_x y R_x es de $-34,22$ dB a una altura de 150 cm sobre el suelo (figura 6.2). Las dos curvas mostradas en la figura 6.2 son importantes porque resumen la mayor y menor atenuación debida a la presencia de vegetación y, por tanto, la mayor y menor cobertura cuando los nodos estaban dispuestos a 50 cm y 150 cm sobre el suelo, respectivamente.

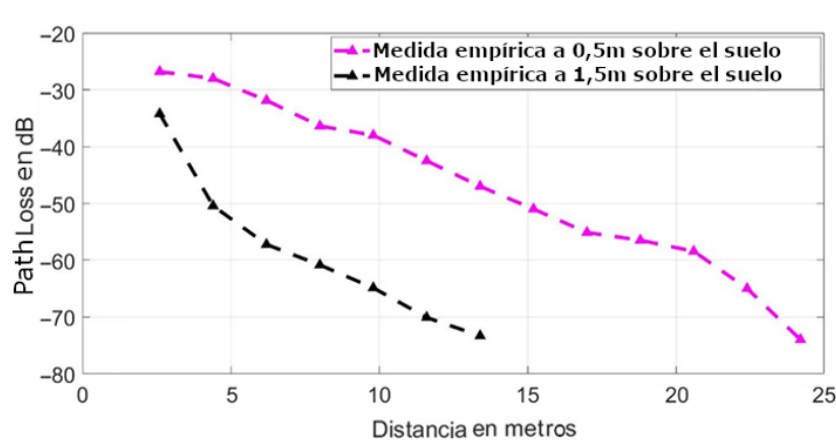


Figura 6.2: Pérdida de trayectoria o atenuación medida en dB de la onda de radio entre el nodo T_x y R_x dentro del invernadero de tomates a 50 cm y 150 cm del suelo.

En las tablas 6.1 y 6.2 se comparan los valores de atenuación de las ondas de radio en presencia de vegetación dentro del invernadero ($PL_{empírico}$) respecto a la distancia de separación de los nodos T_x y R_x , medida en metros cuando están situados a 50 cm y 150 cm del suelo. Las separaciones entre los nodos son inicialmente de 2,6 m y luego aumentan constantemente en 1,8 m debido al marco de plantación que tiene el esquema de la figura 4.5. Las variaciones de valores en atenuaciones se deben a la conformación en la estructura de la vegetación a diferentes alturas. En nuestro caso de estudio, la mayor densidad en vegetación formada por tallos, hojas y frutos se encuentra a una altura de 150 cm.

Tabla 6.1: Atenuación total de la propagación de la onda de radio en presencia de vegetación con nodos a 50 cm del suelo

Modelo	Distancia (m)						
	2,6	4,4	6,2	8	9,8	11,6	13,4
$PL_{empírico}$	26,8	28	31,86	36,38	38	42,5	47

Modelo	Distancia (m)						
	15,2	17,0	18,8	20,6	22,4	24,2	
$PL_{empírico}$	47	51	55,13	56,5	58,44	65	74

Tabla 6.2: Atenuación total de la propagación de la onda de radio en presencia de vegetación con nodos a 150 cm del suelo

Modelo	Distancia (m)						
	2,6	4,4	6,2	8	9,8	11,6	13,4
$PL_{empírico}$	34,22	50,43	57,25	60,85	64,89	70,11	73,33

Con nodos T_x y R_x a 50 cm del suelo, los resultados obtenidos en las pruebas de campo se

compararon a los modelos con LOS, el FSPL y “Dos-Rayos”, a través de los gráficos de curvas que se muestran en la figura 6.3a. En las gráficas 6.3b y 6.3c, los modelos COST235, FITU-R, ITU-R, Weissberger, se suman a las pérdidas del trayecto (con LOS) correspondientes a los pasillos obtenidas con los modelos FSPL y “Dos-Rayos” respectivamente. De todos estos gráficos se concluye que los modelos más cercanos son “Dos-Rayos” y Weissberger añadiendo la atenuación de “Dos-Rayos”. De forma análoga es el análisis en las figuras 6.4a, 6.4b y 6.4c trabajando en este caso con nodos T_x y R_x a 150 cm sobre el suelo.

■ Nuevo modelo optimizado con regresión cúbica y lineal

Se ha utilizado Matlab (R2018a) para desarrollar nuestro modelo optimizado a través de regresión lineal cuando los nodos están a 50 cm de suelo. La ecuación matemática es: $y = -2,0685d - 19,252$ (d es la distancia entre los nodos T_x y R_x). Si los nodos T_x y R_x se colocan a una distancia de 150 cm del suelo, la ecuación matemática del modelo optimizado se obtiene por regresión cúbica utilizando el mismo software, esta vez: $y = -0,056156d^3 + 1,6125d^2 - 17,006d - 0,56299$. Las figuras 6.5a y 6.5b muestran la mejor precisión que tienen respecto a modelos con mayor aproximación de valores, Dos-Rayos y Weissberger a 50 cm y COST235, UIT-R, FITU-R, FSPL para 150 cm.

Asimismo, el porcentaje de error (% error) se halla con la fórmula

$$\left| \left\{ 1 - \left(\frac{X_{i_{empirico}}}{X_{i_{modelo}}} \right) \right\} \cdot 100 \% \right|$$

donde X_i es el valor medido (X_i empírico) o predicho (X_i modelo) en una distancia específica. En nuestros modelos, son inferiores al 9%, mejor que los otros modelos, y se corroboran en las tablas 6.3 y 6.4 en los registros sombreados validando la optimización de las ecuaciones.

Independientemente de la marca o modelo del nodo sensor, los modelos desarrollados posibilitan planificar la distancia máxima que pueden separar dos nodos conociendo la sensibilidad de recepción y EIRP, y a partir de ahí, si se quiere, ampliar la cobertura con una topología multisalto. Por ejemplo, en nuestro caso, la sensibilidad de los nodos es de -100 dBm con EIRP = -24 dBm, y considerando un rango de tolerancia superior a 10 dB es posible obtener rendimientos del 70-100% en los enlaces (Cama-Pinto et al., 2017; Meng y Lee, 2010; Mestre et al., 2010; Sabri et al., 2012; Zennaro et al., 2010) posibilitando enlazar dos nodos a una distancia máxima de 24,2 m y 13,6 m si están a una altura de 50 cm o 150 cm respectivamente.

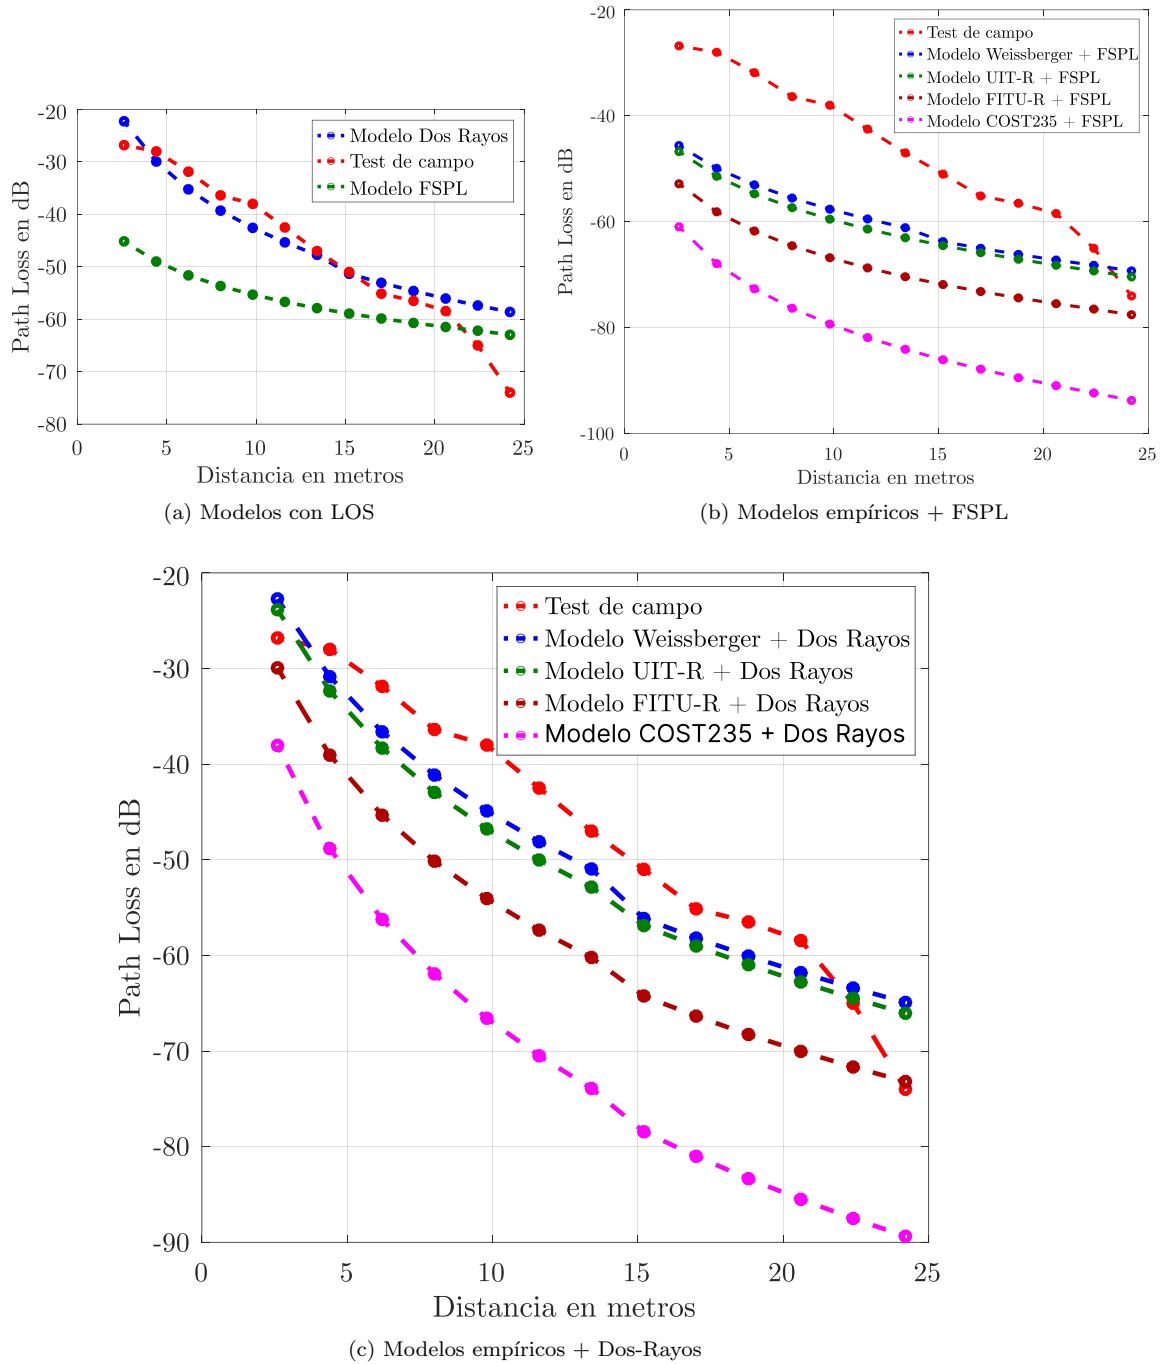


Figura 6.3: Comparación de modelos con medición de campo a 50 cm del suelo

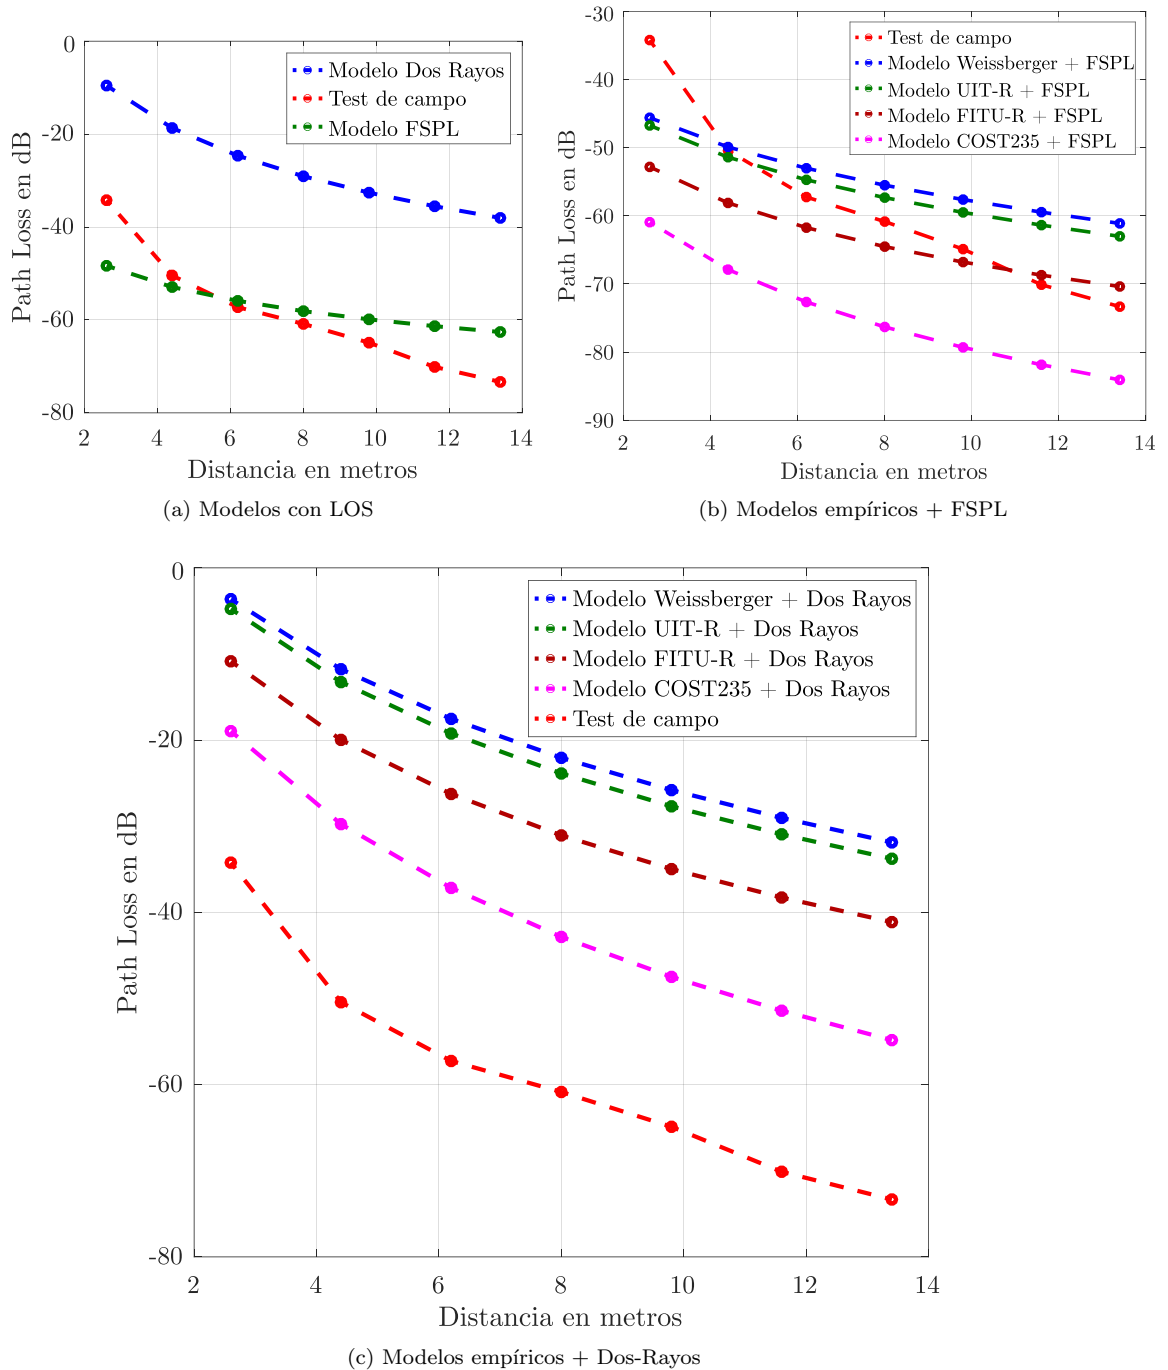
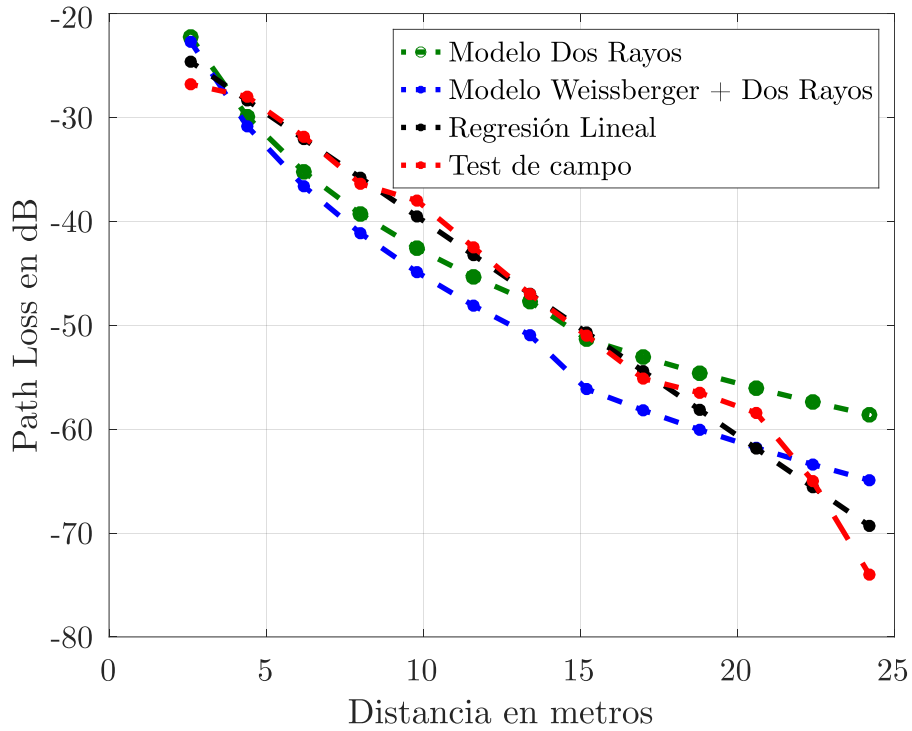
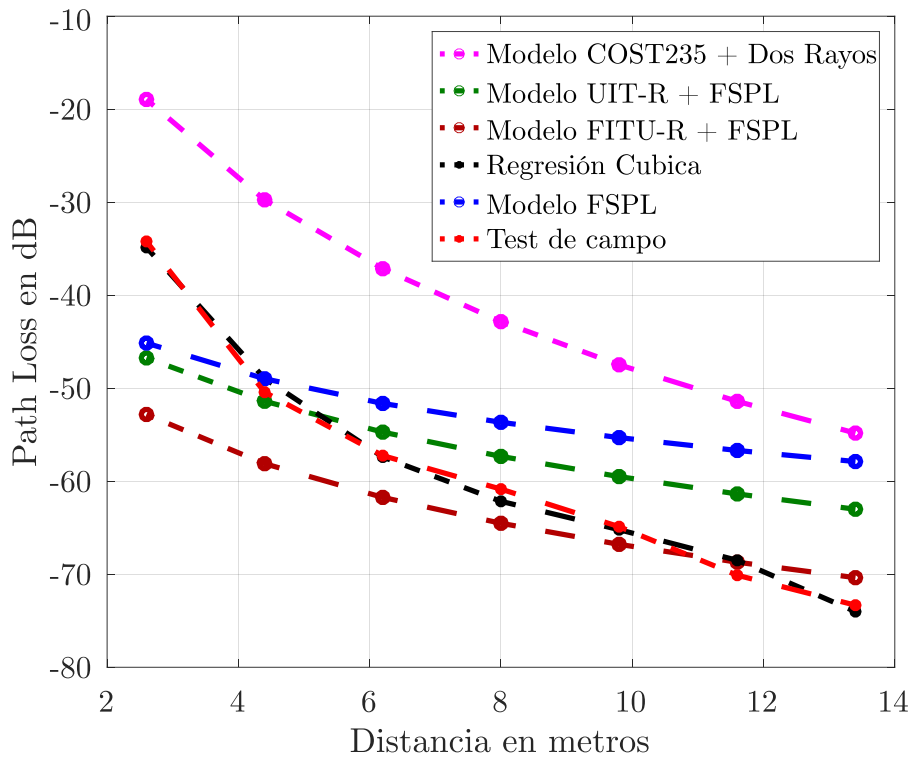


Figura 6.4: Comparación de modelos con medición de campo a 150 cm del suelo



(a) Modelo optimizado (regresión lineal) y otros más cercanos en valores con altura de 50 cm respecto al suelo



(b) Modelo optimizado (regresión cúbica) y otros más cercanos en valores con altura de 150 cm

Figura 6.5: Medición de campo con modelos optimizados

Tabla 6.3: Porcentaje de error en la banda de 2,4 GHz con modelos de propagación en presencia de vegetación cuando los nodos T_x y R_x están a 50 cm del suelo.

% error	Distancia (m)												
	2,6	4,4	6,2	8	9,8	11,6	13,4	15,2	17,0	18,8	20,6	22,4	24,2
FSPL	40,64	42,84	38,30	32,21	31,30	25,04	18,81	13,46	7,92	6,94	4,95	4,52	17,52
“Dos-Rayos”	20,44	6,44	9,57	7,41	10,75	6,27	1,52	0,65	3,91	3,44	4,25	13,27	26,25
Weissberger + “Dos-Rayos”	17,99	9,24	12,99	11,56	15,34	11,66	7,76	9,15	5,25	5,93	5,43	2,51	13,99
Regresión Lineal	8,81	1,25	0,68	1,62	3,85	1,73	0,06	0,61	1,31	2,82	5,53	0,89	6,77

Tabla 6.4: Porcentaje de error en la banda de 2,4 GHz con modelos de propagación en presencia de vegetación cuando los nodos T_x y R_x están a 150 cm del suelo.

% error	Distancia (m)						
	2,6	4,4	6,2	8	9,8	11,6	13,4
FSPL	29,22	4,69	2,43	4,72	8,39	14,31	17,17
“Dos-Rayos”	258,13	169,76	132,23	109,25	99,02	97,30	92,77
COST235 + “Dos-Rayos”	80,52	69,52	54,08	42,02	36,65	36,36	33,75
UIT-R + FSPL	26,79	1,9	4,62	6,13	9,05	14,24	16,37
FITU-R + FSPL	35,22	13,22	7,28	5,69	2,85	2,04	4,20
Regresión cúbica	1,85	3,01	0,26	2,11	0,49	2,34	0,93

Según la literatura revisada, es la primera vez que se desarrollan modelos de propagación de ondas de radio en un invernadero de producción de tomates. A una altura de medio metro sobre el nivel del suelo se consigue mayor cobertura, y los modelos divergen hasta un porcentaje de error del 42,84%, siendo los modelos de Weissberger y “Dos-Rayos” los que más se aproximan. La cobertura más baja se obtiene a 150 cm, y los modelos que más se aproximan a los valores empíricos son los de ITU-R, ITU-R y FSPL que pueden divergir en promedio hasta un porcentaje de error del 30%. Estos dos modelos tienen porcentajes de error inferiores al 9% cuando los nodos están a una altura inferior a un metro y medio, y menos del 3% con medio metro de separación con el suelo.

6.2. Uso de regresión regularizada en datos de pruebas de campo del 2020 y 2018

El modelo creado se contrasta con mediciones experimentales realizadas en cuatro invernaderos en febrero del 2020 y con la medición realizada en febrero del 2018 en el invernadero de La Cañada. Los valores resumidos en la tabla 6.5 revelan que el modelo obtenido se adapta bien a invernaderos de tomate, independientemente del nivel del mar donde se encuentre.

Tabla 6.5: Parámetros de evaluación para mediciones de otros invernaderos. Los invernaderos están situados en La Cañada, Retamar, El Alquíán y Nijar. Todas estas localizaciones están en la provincia de Almería, España.

	Localidad	Año	R^2	R^2 Adj.	MSE	RMSE	MAPE	AIC	SBC
$L_{follaje}(d, h)$	Cañada	2020	0,921	0,920	8,745	2,957	0,408	445	234
$L_{follaje}(d, h)$	Retamar	2020	0,912	0,910	9,196	3,0325	0,261	449	237
$L_{follaje}(d, h)$	Alquíán	2020	0,901	0,899	9,976	3,158	0,242	454	243
$L_{follaje}(d, h)$	Nijar	2020	0,895	0,892	11,486	3,389	0,602	464	253
$L_{follaje}(d, h)$	Cañada	2018	0,902	0,900	10,53	3,245	0,603	458	247

Para analizar el error generalizado, se evaluó el modelo con valores reales para su ajuste. Por tanto, la tabla 6.5 muestran parámetros de evaluación para otras mediciones de invernaderos. Por un lado, el parámetro R^2 está entre 0,921 y 0,895. El R^2 generalizado puede considerarse como su media. La media de R^2 es de 0,906. Por otro lado, el parámetro RMSE está entre 3,389 y 2,957. El RMSE generalizado puede considerarse como su media. La media del RMSE es de 3,156. Tal como se había previsto este error es mayor que el obtenido con valores del modelo de ajuste.

Los valores recogidos durante los ensayos de campo (2018) en el invernadero de tomate de La Cañada, en Almería (España), se contrastaron con la ecuación del modelo propuesto

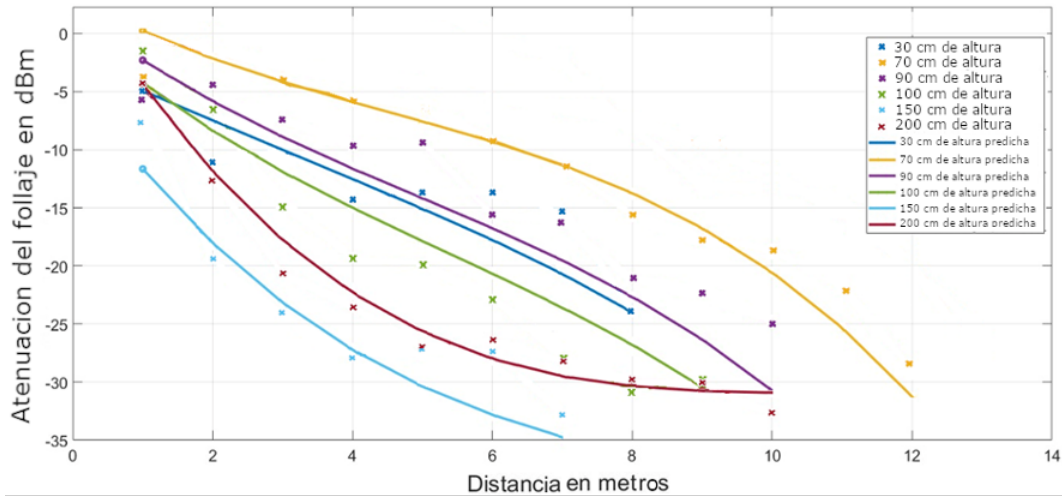


Figura 6.6: Curvas del modelo propuesto frente a valores tomados en las pruebas de campo en el año 2018

(curvas de colores) en el gráfico de la figura 6.6. Nuevamente, como se esperaba, el modelo propuesto se ajusta adecuadamente a datos experimentales.

6.3. Uso de Deep Learning en datos de pruebas de campo del 2020 y 2018

El modelo basado en aprendizaje profundo creado se contrasta con otras mediciones experimentales. Estas mediciones se realizaron en 2020 y 2018. Los valores se resumen en la tabla 6.6 para todos los invernaderos, donde se puede comprobar que el modelo basado en aprendizaje profundo obtenido funciona correctamente.

Tabla 6.6: Evaluación de la calidad estadística del modelo de aprendizaje profundo propuesto para las mediciones de otros invernaderos. Los invernaderos están situados en La Cañada, Retamar, El Alquíán y Níjar. Todas estas localizaciones están en la provincia de Almería, España.

	Localidad	Año	R^2	R^2 Adj.	MSE	RMSE	MAPE	AIC	SBC
$L_{follaje}(d, h)$	Cañada	2019	0,935	0,933	8,32	2,88	0,398	462	250
$L_{follaje}(d, h)$	Retamar	2019	0,926	0,913	8,75	2,95	0,257	465	254
$L_{follaje}(d, h)$	Alquíán	2019	0,913	0,900	9,52	3,08	0,238	475	260
$L_{follaje}(d, h)$	Níjar	2019	0,908	0,910	11,15	3,33	0,594	485	271
$L_{follaje}(d, h)$	Cañada	2018	0,915	0,903	10,17	3,19	0,595	476	264

Para evaluar el error generalizado, se evaluó el modelo con valores reales para su ajuste. Por lo tanto, los parámetros de evaluación para otras medidas de invernadero se muestran en la tabla 6.6. Por un lado, el parámetro R^2 está entre 0,908 y 0,935. El R^2 generalizado puede considerarse como su media. La media de R^2 es de 0,920. Por otro lado, el parámetro

RMSE está entre 2,88 y 3,33. El RMSE generalizado puede considerarse como su media. La media del RMSE es de 3,08. Este error es mayor que el obtenido con los valores de ajuste del modelo, lo que es de esperar.

Capítulo 7

Conclusiones y trabajo futuro

En este capítulo final se describen las conclusiones, las publicaciones derivadas de la investigación y las propuestas de trabajo futuro.

7.1. Conclusiones

Se han realizado mediciones experimentales de la atenuación de las ondas de radio en el interior de un invernadero de tomates mediante una red de sensores inalámbricos que envían señal en la banda ICM de 2,4 GHz. Los datos de atenuación registrados se han comparado con los valores de los modelos empíricos de atenuación en presencia de vegetación existentes, dando un margen de error considerable entre ellos.

En base a esta evidencia, para mejorar la predictibilidad de los modelos empíricos actuales se han desarrollado dos modelos empíricos propios utilizando el método de regresión regularizada y Deep Learning.

Los modelos empíricos propuestos, basado en el modelo de decaimiento exponencial modificado (EDM), toman la distancia entre los nodos como variable e incluye también la altura de sus antenas (de transmisión y de recepción), ya que, como era de esperar, la atenuación se ve más afectada por la variable altura que por la variable distancia.

Por otra parte, los parámetros de evaluación del modelo basado en aprendizaje profundo mostraron mejor robustez y fiabilidad que el de regresión regularizada. Concretamente, el modelo de red neuronal profunda obtuvo 0,966 para R^2 y 0,964 para R_{Adj}^2 . Por último, para

el error generalizado se ha obtenido 0,920 para R^2 y 0,912 para R^2_{Adj} .

Los resultados obtenidos con los modelos desarrollados son beneficiosos en la agricultura de precisión, permitiendo determinar ubicaciones más adecuadas de los nodos sensores, determinando además su número necesario a la hora de planificar su despliegue.

El conjunto de datos de la atenuación de las ondas al interior de un invernadero puede encontrarse en el siguiente enlace (Cama-Pinto et al., 2021b).

7.2. Publicaciones derivadas de la investigación

A continuación se listan las publicaciones indexadas generadas durante la investigación realizada en esta tesis.

- Cama-Pinto, D., Damas-Hermoso, M., Holgado-Terriza, J. A., Arrabal-Campos, F.M., Martínez-Lao, J.A., Manzano-Agugliaro, F., Cama-Pinto, A. (2022). Deep Learning Model of Radio Wave Propagation for Precision Agriculture and Sensor System in Greenhouses. *Agronomy* (Actualmente bajo revisión).
- Cama-Pinto, D., Holgado-Terriza, J. A., Damas-Hermoso, M., Gómez-Mula, F., Cama-Pinto, A. (2021). RadioWave Attenuation Measurement System Based on RSSI for Precision Agriculture: Application to Tomato Greenhouses. *Inventions*, 6(4), 66.
- Cama-Pinto, D., Damas, M., Holgado-Terriza, J. A., Arrabal-Campos, F. M., Gómez-Mula, F., Martínez-Lao, J. A., Cama-Pinto, A. (2020). Empirical model of radio wave propagation in the presence of vegetation inside greenhouses using regularized regressions. *Sensors*, 20(22), 6621.
- Cama-Pinto, D., Damas, M., Holgado-Terriza, J. A., Gómez-Mula, F., Cama-Pinto, A. (2019). Path loss determination using linear and cubic regression inside a classic tomato greenhouse. *International journal of environmental research and public health*, 16(10), 1744.

7.3. Trabajo futuro

La metodología presentada servirá para desarrollar nuevos modelos de atenuación de las ondas de radio en el interior de otros tipos de cultivos, donde la función de atenuación por

presencia de vegetación se deba a dos términos, siendo el primero una atenuación exponencial y el segundo dependiente de una función de compensación relacionada con el entorno donde se propaga la señal. En futuros estudios, es importante investigar la parte compensatoria de nuestra propuesta de ecuación modificada obtenida a partir del modelo de atenuación exponencial modificado (EDM) para implementar nuevos modelos empíricos, pero además para analizar cómo se comportará el modelo si el dispositivo se mueve en función del crecimiento de la planta. Aparte, se debería estudiar el comportamiento de la señal agregando otras variables como lo son la humedad ambiente, temperatura u otros factores ambientales para incluirlas en un nuevo modelo si su impacto es significativo.

También se planea diseñar una nueva solución integrada de hardware y software basada en nuestro sistema de medición de valores RSSI, facilitando su despliegue y uso por parte de los actores de la producción agrícola.

Bibliografía

- Abdelazeem, M. M. Solving ill-posed magnetic inverse problem using a parameterized trust-region sub-problem. *Contributions to Geophysics and Geodesy*, 43(2):99–123, June 2013. doi: 10.2478/congeo-2013-0007.
- Abdollahi, A., Rejeb, K., Rejeb, A., Mostafa, M. M., y Zailani, S. Wireless sensor networks in agriculture: Insights from bibliometric analysis. *Sustainability*, 13(21), 2021. ISSN 2071-1050. doi: 10.3390/su132112011. URL <https://www.mdpi.com/2071-1050/13/21/12011>.
- Abdul-Hammed, M., Olajide, M., Adepoju, A., Adegboyega, S., y Adedotun, I. Quality parameters, empirical and kinetic models of lycopene and beta-carotene bioformation in tomatoes (*solanum lycopersicum*). *Physical Chemistry Research*, 10(1):151–162, 2022. ISSN 2322-5521. doi: 10.22036/pcr.2021.283758.1916. URL https://www.physchemres.org/article_138881.html.
- Adusei, Y. Y., Quaye-Ballard, J., Adjaottor, A. A., y Mensah, A. A. Spatial prediction and mapping of water quality of Owabi reservoir from satellite imageries and machine learning models. *The Egyptian Journal of Remote Sensing and Space Science*, 24(3):825–833, December 2021. ISSN 11109823. doi: 10.1016/j.ejrs.2021.06.006. URL <https://linkinghub.elsevier.com/retrieve/pii/S1110982321000454>.
- Agliari, E., Alemanno, F., Barra, A., y De Marzo, G. The emergence of a concept in shallow neural networks. *Neural Networks*, 148:232–253, 2022. doi: 10.1016/j.neunet.2022.01.017.
- Agrawal, S. K. y Garg, P. Calculation of channel capacity and rician factor in the presence of vegetation in higher altitude platforms communication systems. In *15th International Conference on Advanced Computing and Communications (ADCOM 2007)*, pages 243–248, 2007. doi: 10.1109/ADCOM.2007.37.
- Agrawal, V. Security and privacy issues in wireless sensor networks for healthcare. 7 2015. doi: 10.1007/978-3-319-19656-5_32.
- Aguilera-Sáez, L. M., Arrabal-Campos, F. M., Callejón-Ferre, Á. J., Medina, M. D. S., y Fernández, I. Use of multivariate nmr analysis in the content prediction of hemicellulose, cellulose and lignin in greenhouse crop residues. *Phytochemistry*, 158:110–119, 2019.
- Aishwarya Lakshmi, T., Hariharan, B., y Rekha, P. A survey on energy efficient routing protocol for iot based precision agriculture. In *2019 International Conference on Communication and Electronics Systems (ICCES)*, pages 1284–1288, 2019. doi: 10.1109/ICCES45898.2019.9002410.
- Akhigbe, I., Munir, K., Akinade, O., Akanbi, L., y Oyedele, L. Iot technologies for livestock management: A review of present status, opportunities, and future trends bernard. *Big Data and Cognitive Computing*, 5(1), 2021. doi: 10.3390/bdcc5010010.
- Alalade, A. M., Ndujiuba, C., Adewale, A. A., Ekong, E. E., y Etta, M. N. Design of a fluorescent tube antenna with defined copper wire coupling specifications. *Journal of Physics: Conference Series*, 1378(4): 042095, dec 2019. doi: 10.1088/1742-6596/1378/4/042095. URL <https://doi.org/10.1088/1742-6596/1378/4/042095>.
- Alavi, S. J., Ahmadi, K., Tabari, M., y Aertsen, W. Non-linear height-diameter models for oriental beech (*fagus orientalis lipsky*) in the hyrcanian forests, iran. *Biotechnologie, Agronomie, Société et Environnement*, 17:431–440, 01 2013.
- Albahli, S. y Nabi Ahmad Hassan Yar, G. Defect Prediction Using Akaike and Bayesian Information Criterion. *Computer Systems Science and Engineering*, 41(3):1117–1127, 2022. ISSN 0267-6192. doi: 10.32604/csse.2022.021750. URL <https://www.techscience.com/csse/v41n3/45551>.

- Alibakhshikenari, M., Virdee, B. S., Althuwayb, A. A., Xu, K.-D., See, C. H., Khan, S., Park, I., Falcone, F., y Limiti, E. Novel concentric hexagonal-shaped rfid tag antenna with t-shaped stub matching. *IEEE Journal of Radio Frequency Identification*, 6:112–120, 2022. doi: 10.1109/JRFID.2021.3124966.
- Amali, D, G. B. y M, D. A New Quantum Tunneling Particle Swarm Optimization Algorithm for Training Feedforward Neural Networks. *International Journal of Intelligent Systems and Applications*, 10(11): 64–75, November 2018. ISSN 2074904X, 20749058. doi: 10.5815/ijisa.2018.11.07. URL <http://www.mecs-press.org/ijisa/ijisa-v10-n11/v10n11-7.html>.
- Aminah, N. S., Ramadhani Raharjo, M. R., y Budiman, M. Low-cost wireless mesh communications based on openWRT and voice over internet protocol. *International Journal of Electrical and Computer Engineering (IJECE)*, 11(6):5119, December 2021. ISSN 2722-2578, 2088-8708. doi: 10.11591/ijece.v11i6.pp5119-5126. URL <http://ijece.iaescore.com/index.php/IJECE/article/view/24037>.
- Amutha, J., Sharma, S., y Nagar, J. WSN Strategies Based on Sensors, Deployment, Sensing Models, Coverage and Energy Efficiency: Review, Approaches and Open Issues. *Wireless Personal Communications*, 111(2):1089–1115, March 2020. ISSN 0929-6212, 1572-834X. doi: 10.1007/s11277-019-06903-z. URL <http://link.springer.com/10.1007/s11277-019-06903-z>.
- Anastassiou, H., Vougioukas, S., Fronimos, T., Regen, C., Petrou, L., Zude, M., y Käthner, J. A Computational Model for Path Loss in Wireless Sensor Networks in Orchard Environments. *Sensors*, 14(3):5118–5135, March 2014. ISSN 1424-8220. doi: 10.3390/s140305118. URL <http://www.mdpi.com/1424-8220/14/3/5118>.
- Anderson, C. R., Volos, H. I., y Buehrer, R. M. Characterization of Low-Antenna Ultrawideband Propagation in a Forest Environment. *IEEE Transactions on Vehicular Technology*, 62(7):2878–2895, September 2013. ISSN 0018-9545, 1939-9359. doi: 10.1109/TVT.2013.2251027. URL <http://ieeexplore.ieee.org/document/6484996/>.
- Andrianto, H., Suhardi, y Faizal, A. Development of smart greenhouse system for hydroponic agriculture. pages 335–340, 2020. doi: 10.1109/ICITSI50517.2020.9264917.
- Antolín, D., Medrano, N., y Calvo, B. Reliable Lifespan Evaluation of a Remote Environment Monitoring System Based on Wireless Sensor Networks and Global System for Mobile Communications. *Journal of Sensors*, 2016:1–12, 2016. ISSN 1687-725X, 1687-7268. doi: 10.1155/2016/4248230. URL <http://www.hindawi.com/journals/js/2016/4248230/>.
- Atchadé, M. N. y Sokadjo, Y. M. Overview and cross-validation of COVID-19 forecasting univariate models. *Alexandria Engineering Journal*, 61(4):3021–3036, April 2022. ISSN 11100168. doi: 10.1016/j.aej.2021.08.028. URL <https://linkinghub.elsevier.com/retrieve/pii/S1110016821005470>.
- Aydin, E., Öztürk, B., y Dutkiewicz, M. Analysis of efficiency of passive dampers in multistorey buildings. *Journal of Sound and Vibration*, 439:17–28, January 2019. ISSN 0022460X. doi: 10.1016/j.jsv.2018.09.031. URL <https://linkinghub.elsevier.com/retrieve/pii/S0022460X18306163>.
- Aziz, A., Driouich, A., Bellil, A., Ali, M. B., Mabtouti, S. E., Felaous, K., Achab, M., y El Bouari, A. Optimization of new eco-material synthesis obtained by phosphoric acid attack of natural Moroccan pozzolan using Box-Behnken Design. *Ceramics International*, 47(23):33028–33038, December 2021. ISSN 02728842. doi: 10.1016/j.ceramint.2021.08.203. URL <https://linkinghub.elsevier.com/retrieve/pii/S0272884221025931>.
- Azman, A., Lee, M., Subramaniam, S., y Feroz, F. Novel wireless sensor network routing protocol performance evaluation using diverse packet size for agriculture application. *International Journal of Integrated Engineering*, 13, 05 2021. doi: 10.30880/ijie.2021.13.04.002.
- Azmi, N., Kamarudin, L. M., Zakaria, A., Ndzi, D. L., Rahiman, M. H. F., Zakaria, S. M. M. S., y Mohamed, L. RF-Based Moisture Content Determination in Rice Using Machine Learning Techniques. *Sensors*, 21(5):1875, March 2021. ISSN 1424-8220. doi: 10.3390/s21051875. URL <https://www.mdpi.com/1424-8220/21/5/1875>.
- Aznar-Sánchez, J. A., Velasco-Muñoz, J. F., García-Arca, D., y López-Felices, B. Identification of Opportunities for Applying the Circular Economy to Intensive Agriculture in Almería (South-East Spain). *Agronomy*, 10(10):1499, October 2020. ISSN 2073-4395. doi: 10.3390/agronomy10101499. URL <https://www.mdpi.com/2073-4395/10/10/1499>.
- Balachander, D., Rao, T. R., y Mahesh, G. Rf propagation investigations in agricultural fields and gardens for wireless sensor communications. In *2013 IEEE Conference on Information Communication Technologies*, pages 755–759, 2013. doi: 10.1109/CICT.2013.6558195.

- Banks, H. T. y Joyner, M. L. Adaption of Akaike information criterion under least squares frameworks for comparison of stochastic models. *Quarterly of Applied Mathematics*, 77(4):831–859, May 2019. ISSN 0033-569X, 1552-4485. doi: 10.1090/qam/1542. URL <https://www.ams.org/qam/2019-77-04/S0033-569X-2019-01542-5/>.
- Banteng, L., Yang, H., Chen, Q., y Wang, Z. Research on the subtractive clustering algorithm for mobile ad hoc network based on the Akaike information criterion. *International Journal of Distributed Sensor Networks*, 15(9):155014771987761, September 2019. ISSN 1550-1477, 1550-1477. doi: 10.1177/1550147719877612. URL <http://journals.sagepub.com/doi/10.1177/1550147719877612>.
- Barbieri, A. G., Fre, G. L. S., y Spadoti, D. H. IoT Link Budget Survey for Sub-Gigahertz Field Area Networks. In *2019 SBMO/IEEE MTT-S International Microwave and Optoelectronics Conference (IMOC)*, pages 1–3, Aveiro, Portugal, November 2019. IEEE. ISBN 9781728130996. doi: 10.1109/IMOC43827.2019.9317667. URL <https://ieeexplore.ieee.org/document/9317667/>.
- Bartkowiak, A. Energy-saving and low-emission livestock buildings in the concept of a smart farming. *Journal of Water and Land Development*, 51:272–278, 2021. doi: 10.24425/jwld.2021.139935.
- Bauerdick, J., Treiber, M., y Bernhardt, H. *Smart farming and digitization of research farms-a holistic concept for science and teaching*. 2020. doi: 10.1016/B978-0-12-819774-5.00016-3.
- Behi, M., Bouttout, F., Fortaki, T., y Dumond, C. A novel multifunction implantable antenna design for biomedical telemetry. In *2021 International Applied Computational Electromagnetics Society Symposium (ACES)*, pages 1–4, 2021.
- Benedet, A. L., Brum, W. S., Hansson, O., Alzheimer’s Disease Neuroimaging Initiative, Karikari, T. K., Zimmer, E. R., Zetterberg, H., Blennow, K., y Ashton, N. J. The accuracy and robustness of plasma biomarker models for amyloid PET positivity. *Alzheimer’s Research & Therapy*, 14(1):26, December 2022. ISSN 1758-9193. doi: 10.1186/s13195-021-00942-0. URL <https://alzres.biomedcentral.com/articles/10.1186/s13195-021-00942-0>.
- Bengio, Y., Lecun, Y., y Hinton, G. Deep learning for ai. *Communications of the ACM*, 64(7):58–65, 2021. doi: 10.1145/3448250.
- Bensky, A. Chapter 2 - radio propagation. In Bensky, A., editor, *Short-range Wireless Communication (Third Edition)*, pages 11–41. Newnes, third edition edition, 2019. ISBN 978-0-12-815405-2. doi: <https://doi.org/10.1016/B978-0-12-815405-2.00002-6>. URL <https://www.sciencedirect.com/science/article/pii/B9780128154052000026>.
- Berhich, A., Belouadha, F.-Z., y Kabbaj, M. A location-dependent earthquake prediction using recurrent neural network algorithms. *Soil Dynamics and Earthquake Engineering*, 161, 2022. doi: 10.1016/j.soildyn.2022.107389.
- Bezunartea, M., Wang, C., Braeken, A., y Steenhaut, K. Multi-radio Solution for Improving Reliability in RPL. In *2018 IEEE 29th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, pages 129–134, Bologna, Italy, September 2018. IEEE. ISBN 9781538660096. doi: 10.1109/PIMRC.2018.8580913. URL <https://ieeexplore.ieee.org/document/8580913/>.
- Bhattacharya, S., Biswas, A., Nandi, S., y Patra, S. K. Exhaustive model selection in $b \rightarrow s\ell\ell$ decays: Pitting cross-validation against the akaike information criterion. *Phys. Rev. D*, 101:055025, Mar 2020. doi: 10.1103/PhysRevD.101.055025. URL <https://link.aps.org/doi/10.1103/PhysRevD.101.055025>.
- Bogdány, B. y Tóth, Z. Inversion of artificial neural networks for wifi rssi propagation modeling. volume 2874, pages 67–76, 2021.
- Boursianis, A., Papadopoulou, M., Diamantoulakis, P., Liopa-Tsakalidi, A., Barouchas, P., Salahas, G., Karagiannidis, G., Wan, S., y Goudos, S. Internet of things (iot) and agricultural unmanned aerial vehicles (uavs) in smart farming: A comprehensive review. *Internet of Things (Netherlands)*, 18, 2022. doi: 10.1016/j.iot.2020.100187.
- Bowrothu, R. y Yoon, Y. K. Low Loss Cu/Co Metaconductor Based Array Antenna in Ka Band for 5G Applications. In *2020 IEEE International Symposium on Antennas and Propagation and North American Radio Science Meeting*, pages 35–36, Montreal, QC, Canada, July 2020. IEEE. ISBN 9781728166704. doi: 10.1109/IEEECONF35879.2020.9329531. URL <https://ieeexplore.ieee.org/document/9329531/>.
- Brinkhoff, J. y Hornbuckle, J. Characterization of WiFi signal range for agricultural WSNs. In *2017 23rd Asia-Pacific Conference on Communications (APCC)*, pages 1–6, Perth, WA, December 2017. IEEE. ISBN 9781740523905. doi: 10.23919/APCC.2017.8304043. URL <http://ieeexplore.ieee.org/document/8304043/>.

- Bruniaux, A., Koutsiamanis, R.-A., Papadopoulos, G. Z., y Montavont, N. Defragmenting the 6LoWPAN Fragmentation Landscape: A Performance Evaluation. *Sensors*, 21(5):1711, March 2021. ISSN 1424-8220. doi: 10.3390/s21051711. URL <https://www.mdpi.com/1424-8220/21/5/1711>.
- Caicedo Ortiz, J. G. Modelo de despliegue de una WSN para la medición de las variables climáticas que causan fuertes precipitaciones. *Prospectiva*, 13(1):106, June 2015. ISSN 22161368, 16928261. doi: 10.15665/rp.v13i1.365. URL <http://ojs.uac.edu.co/index.php/prospectiva/article/view/365>.
- Caicedo-Ortiz, J. G., De-la Hoz-Franco, E., Morales Ortega, R., Piñeres-Espitia, G., Combita-Niño, H., Estévez, F., y Cama-Pinto, A. Monitoring system for agronomic variables based in WSN technology on cassava crops. *Computers and Electronics in Agriculture*, 145:275–281, February 2018. ISSN 01681699. doi: 10.1016/j.compag.2018.01.004. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168169917310189>.
- Calamante, F., Gadian, D. G., y Connelly, A. Quantification of bolus-tracking MRI: Improved characterization of the tissue residue function using Tikhonov regularization. *Magnetic Resonance in Medicine*, 50(6):1237–1247, December 2003. ISSN 0740-3194, 1522-2594. doi: 10.1002/mrm.10643. URL <https://onlinelibrary.wiley.com/doi/10.1002/mrm.10643>.
- Calvetti, D., Morigi, S., Reichel, L., y Sgallari, F. Tikhonov regularization and the L-curve for large discrete ill-posed problems. *Journal of Computational and Applied Mathematics*, 123(1-2):423–446, November 2000. ISSN 03770427. doi: 10.1016/S0377-0427(00)00414-3. URL <https://linkinghub.elsevier.com/retrieve/pii/S0377042700004143>.
- Calvetti, D., Reichel, L., y Shuibi, A. L-Curve and Curvature Bounds for Tikhonov Regularization. *Numerical Algorithms*, 35(2-4):301–314, April 2004. ISSN 1017-1398. doi: 10.1023/B:NUMA.0000021764.16526.47. URL <http://link.springer.com/10.1023/B:NUMA.0000021764.16526.47>.
- Cama-Pinto, A., Piñeres-Espitia, G., Caicedo-Ortiz, J., Ramírez-Cerpa, E., Betancur-Agudelo, L., y Gómez-Mula, F. Received strength signal intensity performance analysis in wireless sensor network using Arduino platform and XBee wireless modules. *International Journal of Distributed Sensor Networks*, 13(7):155014771772269, July 2017. ISSN 1550-1477, 1550-1477. doi: 10.1177/1550147717722691. URL <http://journals.sagepub.com/doi/10.1177/1550147717722691>.
- Cama-Pinto, A., Cama-Pinto, D., Damas, M., Holgado-Terriza, J. A., y Gómez-Mula, F. Tomato Greenhouse Measurement of RSSI in Almeria Spain. 2021b. doi: 10.17632/NHK3GS7GMM.1. URL <https://data.mendeley.com/datasets/nhk3gs7gmm/1>. Type: dataset.
- Cama-Pinto, D., Damas, M., Holgado-Terriza, J. A., Gómez-Mula, F., y Cama-Pinto, A. Path Loss Determination Using Linear and Cubic Regression Inside a Classic Tomato Greenhouse. *International Journal of Environmental Research and Public Health*, 16(10):1744, May 2019. ISSN 1660-4601. doi: 10.3390/ijerph16101744. URL <https://www.mdpi.com/1660-4601/16/10/1744>.
- Cama-Pinto, D., Chávez-Muñoz, P. D., Solano-Escorcía, A. F., y Cama-Pinto, A. Data supporting the reconstruction study of missing wind speed logs using wavelet techniques for getting maximum likelihood. *Data in Brief*, 31:105835, August 2020. ISSN 23523409. doi: 10.1016/j.dib.2020.105835. URL <https://linkinghub.elsevier.com/retrieve/pii/S2352340920307290>.
- Cama-Pinto, D., Damas, M., Holgado-Terriza, J. A., Gómez-Mula, F., Calderin-Curtidor, A. C., Martínez-Lao, J., y Cama-Pinto, A. 5G Mobile Phone Network Introduction in Colombia. *Electronics*, 10(8):922, April 2021a. ISSN 2079-9292. doi: 10.3390/electronics10080922. URL <https://www.mdpi.com/2079-9292/10/8/922>.
- Cama-Pinto, D., Holgado-Terriza, J. A., Damas, M., Gómez-Mula, F., y Cama Pinto, A. Tomato greenhouse measurement of rssi in almeria spain. *Mendeley Data*, (1), August 2021b. doi: 10.17632/nhk3gs7gmm.1. URL <https://data.mendeley.com/datasets/nhk3gs7gmm/1>.
- Camacho-Arévalo, R., García-Delgado, C., Mayans, B., Antón-Herrero, R., Cuevas, J., Segura, M. L., y Eymar, E. Sulfonamides in Tomato from Commercial Greenhouses Irrigated with Reclaimed Wastewater: Uptake, Translocation and Food Safety. *Agronomy*, 11(5):1016, May 2021. ISSN 2073-4395. doi: 10.3390/agronomy11051016. URL <https://www.mdpi.com/2073-4395/11/5/1016>.
- Cao, N., Choi, S., Masazade, E., y Varshney, P. K. Sensor Selection for Target Tracking in Wireless Sensor Networks With Uncertainty. *IEEE Transactions on Signal Processing*, 64(20):5191–5204, October 2016. ISSN 1053-587X, 1941-0476. doi: 10.1109/TSP.2016.2595500. URL <http://ieeexplore.ieee.org/document/7524035/>.
- Carvalho, G. C., de Camargo, B. A. F., de Araújo, J. T. C., y Chorilli, M. Lycopene: From tomato to its nutraceutical use and its association with nanotechnology. *Trends in Food Science & Technology*, 118:

- 447–458, December 2021. ISSN 09242244. doi: 10.1016/j.tifs.2021.10.015. URL <https://linkinghub.elsevier.com/retrieve/pii/S0924224421005756>.
- Castillo-Díaz, F. J., Marín-Guirao, J. I., Belmonte-Ureña, L. J., y Tello-Marquina, J. C. Effect of Repeated Plant Debris Reutilization as Organic Amendment on Greenhouse Soil Fertility. *International Journal of Environmental Research and Public Health*, 18(21):11544, November 2021. ISSN 1660-4601. doi: 10.3390/ijerph182111544. URL <https://www.mdpi.com/1660-4601/18/21/11544>.
- Celaya-Echarri, Azpilicueta, López-Iturri, Aguirre, y Falcone. Performance Evaluation and Interference Characterization of Wireless Sensor Networks for Complex High-Node Density Scenarios. *Sensors*, 19(16): 3516, August 2019. ISSN 1424-8220. doi: 10.3390/s19163516. URL <https://www.mdpi.com/1424-8220/19/16/3516>.
- Cesari, M., Stefani, A., Mitterling, T., Frauscher, B., Schönwald, S. V., y Högl, B. Sleep modelled as a continuous and dynamic process predicts healthy ageing better than traditional sleep scoring. *Sleep Medicine*, 77:136–146, January 2021. ISSN 13899457. doi: 10.1016/j.sleep.2020.11.033. URL <https://linkinghub.elsevier.com/retrieve/pii/S1389945720305335>.
- Chaiwatpongsakorn, C., Lu, M., Keener, T., y Khang, S.-J. The Deployment of Carbon Monoxide Wireless Sensor Network (CO-WSN) for Ambient Air Monitoring. *International Journal of Environmental Research and Public Health*, 11(6):6246–6264, June 2014. ISSN 1660-4601. doi: 10.3390/ijerph110606246. URL <http://www.mdpi.com/1660-4601/11/6/6246>.
- Chang, W., Ji, X., Wang, L., Liu, H., Zhang, Y., Chen, B., y Zhou, S. A Machine-Learning Method of Predicting Vital Capacity Plateau Value for Ventilatory Pump Failure Based on Data Mining. *Healthcare*, 9(10):1306, September 2021. ISSN 2227-9032. doi: 10.3390/healthcare9101306. URL <https://www.mdpi.com/2227-9032/9/10/1306>.
- Chee, K. L., Torrico, S. A., y Kurner, T. Foliage Attenuation Over Mixed Terrains in Rural Areas for Broadband Wireless Access at 3.5 GHz. *IEEE Transactions on Antennas and Propagation*, 59(7):2698–2706, July 2011. ISSN 0018-926X, 1558-2221. doi: 10.1109/TAP.2011.2152340. URL <http://ieeexplore.ieee.org/document/5765439/>.
- Chen, D., Zhuang, Y., Huai, J., Sun, X., Yang, X., Awais Javed, M., Brown, J., Sheng, Z., y Thompson, J. Coexistence and Interference Mitigation for WPANs and WLANs From Traditional Approaches to Deep Learning: A Review. *IEEE Sensors Journal*, 21(22):25561–25589, November 2021. ISSN 1530-437X, 1558-1748, 2379-9153. doi: 10.1109/JSEN.2021.3117399. URL <https://ieeexplore.ieee.org/document/9557305/>.
- Chen, T.-S., Chen, J.-J., y Wu, C.-H. Distributed object tracking using moving trajectories in wireless sensor networks. *Wireless Networks*, 22(7):2415–2437, October 2016. ISSN 1022-0038, 1572-8196. doi: 10.1007/s11276-015-1107-9. URL <http://link.springer.com/10.1007/s11276-015-1107-9>.
- Cheng, X., Hou, K. M., y Li, Z. New advances on environment monitoring with wireless sensor network. *International Journal of Distributed Sensor Networks*, 12(7):2378070, 2016. doi: 10.1177/155014772378070. URL <https://doi.org/10.1177/155014772378070>.
- Cornelis, J., Schenkels, N., y Vanroose, W. Projected newton method for noise constrained tikhonov regularization. *Inverse Problems*, 36(5), 2020. doi: 10.1088/1361-6420/ab7d2b.
- Correia, F. P., Alencar, M. S. d., Lopes, W. T. A., Assis, M. S. d., y Leal, B. G. Propagation Analysis for Wireless Sensor Networks Applied to Viticulture. *International Journal of Antennas and Propagation*, 2017:1–10, 2017. ISSN 1687-5869, 1687-5877. doi: 10.1155/2017/7903839. URL <https://www.hindawi.com/journals/ijap/2017/7903839/>.
- Cuinas, I. y Gay-Fernandez, J. A. A proposal on spatial diversity in emergency communications within forest environments. In *The 8th European Conference on Antennas and Propagation (EuCAP 2014)*, pages 1295–1298, The Hague, Netherlands, April 2014. IEEE. ISBN 9788890701849. doi: 10.1109/EuCAP.2014.6902013. URL <http://ieeexplore.ieee.org/document/6902013/>.
- Dai, D. An introduction of cnn: Models and training on neural network models. pages 135–138, 2021. doi: 10.1109/ICBAR55169.2021.00037.
- Dayioğlu, M. y Türker, U. Digital transformation for sustainable future-agriculture 4.0: A review. *Tarım Bilimleri Dergisi*, 27(4):373–399, 2021. doi: 10.15832/ankutbd.986431.
- de Sales Bezerra, T., Rodrigues de Sousa, J. A., da Silva Eleuterio, S. A., y Rocha, J. S. Accuracy of propagation models to power prediction in WSN ZigBee applied in outdoor environment. In *2015 Sixth Argentine Conference on Embedded Systems (CASE)*, pages 19–24, Buenos Aires, August

2015. IEEE. ISBN 9789874552341 9789874552358. doi: 10.1109/SASE-CASE.2015.7295842. URL <https://ieeexplore.ieee.org/document/7295842/>.
- del Felipe, M. R. C., Vázquez, M. L., y Bermello, J. L. P. Wireless Sensor Network Applied to Precision Agriculture: A Technical Case Study at the Technical University of Manabí. In Rocha, Á., López-López, P. C., y Salgado-Guerrero, J. P., editors, *Communication, Smart Technologies and Innovation for Society*, volume 252, pages 525–534. Springer Singapore, Singapore, 2022. ISBN 9789811641251 9789811641268. doi: 10.1007/978-981-16-4126-8_47. URL https://link.springer.com/10.1007/978-981-16-4126-8_47.
- Deroussi, A., Alihamidi, I., Charaf, L. A., Madi, A. A., y Addaim, A. Routing Protocols for WSN: A Survey Precision Agriculture Case Study. In *2020 IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)*, pages 1–7, Kenitra, Morocco, December 2020. IEEE. ISBN 9781728169217. doi: 10.1109/ICECOCS50124.2020.9314630. URL <https://ieeexplore.ieee.org/document/9314630/>.
- Djosic, S., Stojanovic, I., Jovanovic, M., y Djordjevic, G. L. Multi-algorithm UWB-based localization method for mixed LOS/NLOS environments. *Computer Communications*, 181:365–373, January 2022. ISSN 01403664. doi: 10.1016/j.comcom.2021.10.031. URL <https://linkinghub.elsevier.com/retrieve/pii/S0140366421004114>.
- Dubrovin, K. N., Stepanov, A. S., y Aseeva, T. A. Application of LAI and NDVI to model soybean yield in the regions of the Russian Far East. *IOP Conference Series: Earth and Environmental Science*, 949 (1):012030, January 2022. ISSN 1755-1307, 1755-1315. doi: 10.1088/1755-1315/949/1/012030. URL <https://iopscience.iop.org/article/10.1088/1755-1315/949/1/012030>.
- Dunkels, A., Gronvall, B., y Voigt, T. Contiki - a lightweight and flexible operating system for tiny networked sensors. In *29th Annual IEEE International Conference on Local Computer Networks*, pages 455–462, Tampa, FL, USA, 2004. IEEE (Comput. Soc.). ISBN 9780769522609. doi: 10.1109/LCN.2004.38. URL <http://ieeexplore.ieee.org/document/1367266/>.
- Dunkels, A. Contiki: Bringing ip to sensor networks. *ERCIM News*, 2013.
- Dunkels, A., Österlind, F., y He, Z. An adaptive communication architecture for wireless sensor networks. In *Proceedings of the 5th international conference on Embedded networked sensor systems - SenSys '07*, page 335, Sydney, Australia, 2007. ACM Press. ISBN 9781595937636. doi: 10.1145/1322263.1322295. URL <http://portal.acm.org/citation.cfm?doid=1322263.1322295>.
- Duque-Acevedo, M., Belmonte-Ureña, L. J., Toresano-Sánchez, F., y Camacho-Ferre, F. Biodegradable Raffia as a Sustainable and Cost-Effective Alternative to Improve the Management of Agricultural Waste Biomass. *Agronomy*, 10(9):1261, August 2020. ISSN 2073-4395. doi: 10.3390/agronomy10091261. URL <https://www.mdpi.com/2073-4395/10/9/1261>.
- Eagle, S. J., Hancke, G. P., y Silva, B. J. Wireless sensor networks for safety protocols in the industry. In *AFRICON 2015*, pages 1–5, Addis Ababa, Ethiopia, September 2015. IEEE. ISBN 9781479974986. doi: 10.1109/AFRCON.2015.7332009. URL <http://ieeexplore.ieee.org/document/7332009/>.
- Ebongue, J. L. F. K., Nelson, M., y Nlong, J. M. Empirical Path Loss Models for 802.11n Wireless Networks at 2.4 GHz in Rural Regions. In Nungu, A., Pehrson, B., y Sansa-Otim, J., editors, *e-Infrastructure and e-Services for Developing Countries*, volume 147, pages 53–63. Springer International Publishing, Cham, 2015. ISBN 9783319168852 9783319168869. doi: 10.1007/978-3-319-16886-9_6. URL http://link.springer.com/10.1007/978-3-319-16886-9_6.
- Edwards-Murphy, F., Magno, M., Whelan, P. M., O'Halloran, J., y Popovici, E. M. b+WSN: Smart beehive with preliminary decision tree analysis for agriculture and honey bee health monitoring. *Computers and Electronics in Agriculture*, 124:211–219, June 2016. ISSN 01681699. doi: 10.1016/j.compag.2016.04.008. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168169916301235>.
- Escamilla-Rivera, C., Carvajal, M., Zamora, C., y Hendry, M. Neural networks and standard cosmography with newly calibrated high redshift grb observations. *Journal of Cosmology and Astroparticle Physics*, 2022(4), 2022. doi: 10.1088/1475-7516/2022/04/016.
- Esmailzadeh, R. *Chapter 4 - Broadband Telecommunications Technologies and Management*. Wiley Publishing, 1st edition, 2016. ISBN 1118995627.
- Ezuma, M., Anjinappa, C. K., Funderburk, M., y Guvenc, I. Radar Cross Section Based Statistical Recognition of UAVs at Microwave Frequencies. *IEEE Transactions on Aerospace and Electronic Systems*, 58(1): 27–46, February 2022. ISSN 0018-9251, 1557-9603, 2371-9877. doi: 10.1109/TAES.2021.3096875. URL <https://ieeexplore.ieee.org/document/9484736/>.

- Faculty of Electrical and Electronic Engineering, Universiti Tun Hussein Onn Malaysia, Batu Pahat, Johor, Malaysia, Yin Yap, X., Seng Chia, K., Faculty of Electrical and Electronic Engineering, Universiti Tun Hussein Onn Malaysia, Batu Pahat, Johor, Malaysia, Sek Tee, K., y Faculty of Electrical and Electronic Engineering, Universiti Tun Hussein Onn Malaysia, Batu Pahat, Johor, Malaysia. A Portable Gas Pressure Control and Data Acquisition System using Regression Models. *International Journal on Electrical Engineering and Informatics*, 13(1):242–251, March 2021. ISSN 20856830, 20875886. doi: 10.15676/ijeei.2021.13.1.14. URL <http://ijeei.org/docs-2031767190606c2f087c220.pdf>.
- Fahmi, R., Eck, B. L., Levi, J., Fares, A., Dhanantwari, A., Vembar, M., Bezerra, H. G., y Wilson, D. L. Quantitative myocardial perfusion imaging in a porcine ischemia model using a prototype spectral detector CT system. *Physics in Medicine and Biology*, 61(6):2407–2431, March 2016. ISSN 0031-9155, 1361-6560. doi: 10.1088/0031-9155/61/6/2407. URL <https://iopscience.iop.org/article/10.1088/0031-9155/61/6/2407>.
- Fahrion, M. Ten things to remember about wireless communications. *Electronics World*, 118(1917):32–34, 2012.
- Farahani, S. RF Propagation, Antennas, and Regulatory Requirements. In *ZigBee Wireless Networks and Transceivers*, pages 171–206. Elsevier, 2008. ISBN 9780750683937. doi: 10.1016/B978-0-7506-8393-7.00005-4. URL <https://linkinghub.elsevier.com/retrieve/pii/B9780750683937000054>.
- Faroughi, S. A., Roriz, A. I., y Fernandes, C. A Meta-Model to Predict the Drag Coefficient of a Particle Translating in Viscoelastic Fluids: A Machine Learning Approach. *Polymers*, 14(3):430, January 2022. ISSN 2073-4360. doi: 10.3390/polym14030430. URL <https://www.mdpi.com/2073-4360/14/3/430>.
- Farris, A., Vizcarra, J., Amgad, M., Cooper, L., Gutman, D., y Hogan, J. Artificial intelligence and algorithmic computational pathology: an introduction with renal allograft examples. *Histopathology*, 78(6): 791–804, 2021. doi: 10.1111/his.14304.
- Ferreira Neto, M. L., Montez, C., Leao, E., y Cavalca Andrade, A. T. Data-driven Bottom-up Cluster-tree Formation based on the IEEE 802.15.4/ZigBee Protocols. In *IECON 2021 – 47th Annual Conference of the IEEE Industrial Electronics Society*, pages 1–6, Toronto, ON, Canada, October 2021. IEEE. ISBN 9781665435543. doi: 10.1109/IECON48115.2021.9589465. URL <https://ieeexplore.ieee.org/document/9589465/>.
- Foerster, A., Udugama, A., Görg, C., Kuladinithi, K., Timm-Giel, A., y Cama-Pinto, A. A Novel Data Dissemination Model for Organic Data Flows. In Agüero, R., Zinner, T., García-Lozano, M., Wenning, B.-L., y Timm-Giel, A., editors, *Mobile Networks and Management*, volume 158, pages 239–252. Springer International Publishing, Cham, 2015. ISBN 9783319269245 9783319269252. doi: 10.1007/978-3-319-26925-2_18. URL http://link.springer.com/10.1007/978-3-319-26925-2_18.
- Franch, B., Bautista, A. S., Fita, D., Rubio, C., Tarrazó-Serrano, D., Sánchez, A., Skakun, S., Vermote, E., Becker-Reshef, I., y Uris, A. Within-Field Rice Yield Estimation Based on Sentinel-2 Satellite Data. *Remote Sensing*, 13(20):4095, October 2021. ISSN 2072-4292. doi: 10.3390/rs13204095. URL <https://www.mdpi.com/2072-4292/13/20/4095>.
- Franchini, G., Ruggiero, V., Porta, F., y Zanni, L. Neural architecture search via standard machine learning methodologies. *Mathematics In Engineering*, 5(1), 2023. doi: 10.3934/MINE.2023012.
- Franklin, J. N. On Tikhonov’s method for ill-posed problems. *Mathematics of Computation*, 28(128): 889–907, 1974. ISSN 0025-5718, 1088-6842. doi: 10.1090/S0025-5718-1974-0375817-5. URL <https://www.ams.org/mcom/1974-28-128/S0025-5718-1974-0375817-5/>.
- França, R., Monteiro, A., Arthur, R., y Iano, Y. *An overview of internet of things technology applied on precision agriculture concept*. 2020. doi: 10.4018/978-1-7998-5000-7.ch003.
- Frenzel, L. Millimeter waves will expand the wireless future. *Electronic Design*, 6, 2013.
- Friis, H. A Note on a Simple Transmission Formula. *Proceedings of the IRE*, 34(5):254–256, May 1946. ISSN 0096-8390. doi: 10.1109/JRPROC.1946.234568. URL <http://ieeexplore.ieee.org/document/1697062/>.
- Galvan-Tejada, G. M. y Duarte-Reynoso, E. Q. A study based on the Lee propagation model for a wireless sensor network on a non-uniform vegetation environment. In *2012 IEEE Latin-America Conference on Communications*, pages 1–6, Cuenca, November 2012. IEEE. ISBN 9781467350792 9781467350808. doi: 10.1109/LATINCOM.2012.6506004. URL <https://ieeexplore.ieee.org/document/6506004/>.
- Galvan-Tejada, G. M., Duarte-Reynoso, E. Q., y Flores-Leal, R. Standard conditions of propagation for wireless sensor networks in an inhomogeneous vegetation environment. In *2013 IEEE Antennas and Propagation Society International Symposium (APSURSI)*, pages 2014–2015, 2013. doi: 10.1109/APS.2013.6711665.

- Gao, Y. y No, A. Age Estimation from fMRI Data Using Recurrent Neural Network. *Applied Sciences*, 12(2): 749, January 2022. ISSN 2076-3417. doi: 10.3390/app12020749. URL <https://www.mdpi.com/2076-3417/12/2/749>.
- García, L., Parra, L., Jimenez, J. M., Parra, M., Lloret, J., Mauri, P. V., y Lorenz, P. Deployment Strategies of Soil Monitoring WSN for Precision Agriculture Irrigation Scheduling in Rural Areas. *Sensors*, 21(5): 1693, March 2021. ISSN 1424-8220. doi: 10.3390/s21051693. URL <https://www.mdpi.com/1424-8220/21/5/1693>.
- Gay-Fernandez, J. A. y Cuinas, I. Short-Term Modeling in Vegetation Media at Wireless Network Frequency Bands. *IEEE Transactions on Antennas and Propagation*, 62(6):3330–3337, June 2014. ISSN 0018-926X, 1558-2221. doi: 10.1109/TAP.2014.2314459. URL <http://ieeexplore.ieee.org/document/6781052/>.
- Gay-Fernández, J. A. y Cuiñas, I. Peer to peer propagation in vegetation media for wireless sensor networks. In *Proceedings of the 2012 IEEE International Symposium on Antennas and Propagation*, pages 1–2, 2012. doi: 10.1109/APS.2012.6348620.
- Gazzola, S., Kilmer, M. E., Nagy, J. G., Semerci, O., y Miller, E. L. An inner–outer iterative method for edge preservation in image restoration and reconstruction *. *Inverse Problems*, 36(12):124004, December 2020. ISSN 0266-5611, 1361-6420. doi: 10.1088/1361-6420/abb299. URL <https://iopscience.iop.org/article/10.1088/1361-6420/abb299>.
- Ghorbel, O., Ayadi, R., Alanazi, A. S., Alanazi, R., N.Alabdali, R., y Abid, M. Adaptive KPCA for Outlier detection in Wireless Sensor Networks: Water pipeline case. In *2021 International Symposium on Networks, Computers and Communications (ISNCC)*, pages 1–5, Dubai, United Arab Emirates, October 2021. IEEE. ISBN 9781665403047. doi: 10.1109/ISNCC52172.2021.9615708. URL <https://ieeexplore.ieee.org/document/9615708/>.
- Gkioulekas, I. y Papageorgiou, L. G. Piecewise Regression through the Akaike Information Criterion using Mathematical Programming. *IFAC-PapersOnLine*, 51(15):730–735, 2018. ISSN 24058963. doi: 10.1016/j.ifacol.2018.09.168. URL <https://linkinghub.elsevier.com/retrieve/pii/S2405896318318305>.
- Goel, K. y Bindal, A. K. Regulated Energy Harvesting Scheme for Self-Sustaining WSN in Precision Agriculture. In Gupta, D., Polkowski, Z., Khanna, A., Bhattacharyya, S., y Castillo, O., editors, *Proceedings of Data Analytics and Management*, volume 91, pages 367–385. Springer Singapore, Singapore, 2022. ISBN 9789811662843 9789811662850. doi: 10.1007/978-981-16-6285-0_30. URL https://link.springer.com/10.1007/978-981-16-6285-0_30.
- Gohain, P. B. y Jansson, M. Scale-Invariant and consistent Bayesian information criterion for order selection in linear regression models. *Signal Processing*, 196:108499, July 2022. ISSN 01651684. doi: 10.1016/j.sigpro.2022.108499. URL <https://linkinghub.elsevier.com/retrieve/pii/S0165168422000469>.
- Gramatica, P. On the Development and Validation of QSAR Models. In Reisfeld, B. y Mayeno, A. N., editors, *Computational Toxicology*, volume 930, pages 499–526. Humana Press, Totowa, NJ, 2013. ISBN 9781627030588 9781627030595. doi: 10.1007/978-1-62703-059-5_21. URL http://link.springer.com/10.1007/978-1-62703-059-5_21.
- Granda, F., Azpilicueta, L., Vargas-Rosales, C., Lopez-Iturri, P., Aguirre, E., y Falcone, F. Integration of Wireless Sensor Networks in Intelligent Transportation Systems within Smart City Context. In *2018 IEEE International Symposium on Antennas and Propagation & USNC/URSI National Radio Science Meeting*, pages 375–376, Boston, MA, July 2018. IEEE. ISBN 9781538671023. doi: 10.1109/APUSNCURSINRSM.2018.8608746. URL <https://ieeexplore.ieee.org/document/8608746/>.
- Guo, X.-m., Yang, X.-t., Chen, M.-x., Li, M., y Wang, Y.-a. A model with leaf area index and apple size parameters for 2.4 GHz radio propagation in apple orchards. *Precision Agriculture*, 16(2):180–200, April 2015. ISSN 1385-2256, 1573-1618. doi: 10.1007/s11119-014-9369-2. URL <http://link.springer.com/10.1007/s11119-014-9369-2>.
- Gómez, J., Villar, E., Molero, G., y Cama, A. Evaluation of high performance clusters in private cloud computing environments. *Advances in Intelligent and Soft Computing*, 151 AISC:305–312, 2012. doi: 10.1007/978-3-642-28765-7_36.
- Haber, R., Peter, A., Otero, C. E., Kostanic, I., y Ejnoui, A. A support vector machine for terrain classification in on-demand deployments of wireless sensor networks. In *2013 IEEE International Systems Conference (SysCon)*, pages 841–846, Orlando, FL, April 2013. IEEE. ISBN 9781467331081 9781467331074 9781467331067. doi: 10.1109/SysCon.2013.6549982. URL <https://ieeexplore.ieee.org/document/6549982>.
- Halbauer, H. y Wild, T. Towards Power Efficient 6G Sub-THz Transmission. In *2021 Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit)*, pages 25–30, Porto,

- Portugal, June 2021. IEEE. ISBN 9781665415262. doi: 10.1109/EuCNC/6GSummit51104.2021.9482446. URL <https://ieeexplore.ieee.org/document/9482446/>.
- Hamasaki, T. Propagation Characteristics of A 2.4GHz Wireless Sensor Module with A Pattern Antenna in Forestry and Agriculture Field. In *2019 IEEE International Symposium on Radio-Frequency Integration Technology (RFIT)*, pages 1–3, Nanjing, China, August 2019. IEEE. ISBN 9781728124964. doi: 10.1109/RFIT.2019.8929207. URL <https://ieeexplore.ieee.org/document/8929207/>.
- Hansen, P. C. *Rank-deficient and discrete ill-posed problems: numerical aspects of linear inversion*. SIAM monographs on mathematical modeling and computation. SIAM, Philadelphia, 1998. ISBN 9780898714036.
- Hao Chai, A. Y., Hung Lai, C., Su, H. T., Chen Yi Lim, N., Vithanawasam, C. K., Then, Y. L., Siang Tay, F., y Yong, L. Parametric Model Study for Outdoor Routers Cost Estimation. In *2020 13th International UNIMAS Engineering Conference (EnCon)*, pages 1–7, Kota Samarahan, Malaysia, October 2020. IEEE. ISBN 9781728192932. doi: 10.1109/EnCon51501.2020.9299346. URL <https://ieeexplore.ieee.org/document/9299346/>.
- Haslett, C. *Propagation in free space and the aperture antenna*. Cambridge University Press, 2008. ISBN 978-0-511-37112-7.
- Honoré, M. N., Belmonte-Ureña, L. J., Navarro-Velasco, A., y Camacho-Ferre, F. Profit Analysis of Papaya Crops under Greenhouses as an Alternative to Traditional Intensive Horticulture in Southeast Spain. *International Journal of Environmental Research and Public Health*, 16(16):2908, August 2019. ISSN 1660-4601. doi: 10.3390/ijerph16162908. URL <https://www.mdpi.com/1660-4601/16/16/2908>.
- Hsiao, S.-J. y Sung, W.-T. A Study on Using a Wireless Sensor Network to Design a Plant Monitoring System. *Intelligent Automation & Soft Computing*, 27(2):359–377, 2021. ISSN 1079-8587. doi: 10.32604/iasc.2021.014905. URL <https://www.techscience.com/iasc/v27n2/41252>.
- Hu, X., Yan, H., Wang, X., Wang, Z., Li, Y., Zheng, L., Yang, J., Jing, W., Cheng, X., Wei, F., y Ma, S. Machine learning methods to predict the cultivation age of Panacis Quinquefolii Radix. *Chinese Medicine*, 16(1):100, December 2021. ISSN 1749-8546. doi: 10.1186/s13020-021-00511-5. URL <https://cmjournal.biomedcentral.com/articles/10.1186/s13020-021-00511-5>.
- Huang, C.-N. y Chan, C.-T. A ZigBee-Based Location-Aware Fall Detection System for Improving Elderly Telecare. *International Journal of Environmental Research and Public Health*, 11(4):4233–4248, April 2014. ISSN 1660-4601. doi: 10.3390/ijerph110404233. URL <http://www.mdpi.com/1660-4601/11/4/4233>.
- Hysell, D. *Aperture Antennas*, page 98–120. Cambridge University Press, 2018. doi: 10.1017/9781108164122.005.
- Ikbali, N. A. M., Halim, S. A., y Ali, N. Estimating Weibull Parameters Using Maximum Likelihood Estimation and Ordinary Least Squares: Simulation Study and Application on Meteorological Data. *Mathematics and Statistics*, 10(2):269–292, March 2022. ISSN 2332-2071, 2332-2144. doi: 10.13189/ms.2022.100201. URL http://www.hrpub.org/journals/article_info.php?aid=11835.
- Instruments, T. Descripción cc2538. 2015. URL <http://www.ti.com/product/CC2538/description>.
- Ito, S. y Hayashi, T. Radio propagation estimation in a long-range environment using a deep neural network. 2021. doi: 10.23919/EuCAP51087.2021.9411398.
- Jaigirdar, F. T. y Islam, M. M. A new cost-effective approach for battlefield surveillance in wireless sensor networks. In *2016 International Conference on Networking Systems and Security (NSysS)*, pages 1–6, Dhaka, Bangladesh, January 2016. IEEE. ISBN 9781509002030. doi: 10.1109/NSysS.2016.7400694. URL <http://ieeexplore.ieee.org/document/7400694/>.
- Jia, Z. y Yang, Y. A joint bidiagonalization based iterative algorithm for large scale general-form Tikhonov regularization. *Applied Numerical Mathematics*, 157:159–177, November 2020. ISSN 01689274. doi: 10.1016/j.apnum.2020.06.001. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168927420301732>.
- K, V. y G, N. Emerging Line of Research Approach in Precision Agriculture: An Insight Study. *International Journal of Advanced Computer Science and Applications*, 12(2), 2021. ISSN 21565570, 2158107X. doi: 10.14569/IJACSA.2021.0120239. URL <http://thesai.org/Publications/ViewPaper?Volume=12&Issue=2&Code=IJACSA&SerialNo=39>.
- Kabilan, N. y Selvi, M. S. Surveillance and steering of irrigation system in cloud using Wireless Sensor Network and Wi-Fi module. In *2016 International Conference on Recent Trends in Information Technology (ICRTIT)*, pages 1–5, Chennai, India, April 2016. IEEE. ISBN 9781467398022. doi: 10.1109/ICRTIT.2016.7569526. URL <http://ieeexplore.ieee.org/document/7569526/>.

- Kavlakoglu, E. Ai vs. machine learning vs. deep learning vs. neural networks: What's the difference?, 2020. URL <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>.
- Khairunni, S., Ramli, N., y Muharam, F. M. Wireless Sensor Network (WSN) Applications in Plantation Canopy Areas: A Review. *Asian Journal of Scientific Research*, 11(2):151–161, March 2018. ISSN 19921454. doi: 10.3923/ajsr.2018.151.161. URL <https://www.scialert.net/abstract/?doi=ajsr.2018.151.161>.
- Khan, S. K., Farasat, M., Naseem, U., y Ali, F. Performance Evaluation of Next-Generation Wireless (5G) UAV Relay. *Wireless Personal Communications*, 113(2):945–960, July 2020. ISSN 0929-6212, 1572-834X. doi: 10.1007/s11277-020-07261-x. URL <https://link.springer.com/10.1007/s11277-020-07261-x>.
- Khan, Z. A. y Herrmann, P. Energy-efficient Protection of IoT Networks using Trust Management on the IEEE 802.15.4 Protocol. In *2021 11th IFIP International Conference on New Technologies, Mobility and Security (NTMS)*, pages 1–7, Paris, France, April 2021. IEEE. ISBN 9781665443999. doi: 10.1109/NTMS49979.2021.9432670. URL <https://ieeexplore.ieee.org/document/9432670/>.
- Kim, Y., Boo, S., Kim, G., Kim, N., y Lee, B. Wireless Power Transfer Efficiency Formula Applicable in Near and Far Fields. *Journal of Electromagnetic Engineering and Science*, 19(4):239–244, October 2019. ISSN 2671-7255, 2671-7263. doi: 10.26866/jees.2019.19.4.239. URL <http://jees.kr/journal/view.php?doi=10.26866/jees.2019.19.4.239>.
- Koley, S., Roy, H., Dhar, S., y Bhattacharjee, D. Edge Detection based on Local-Friis-Radiation-Magnitude-Ratio (LFRMR). In *2020 Fifth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)*, pages 99–104, Bangalore, India, November 2020. IEEE. ISBN 9781728188188. doi: 10.1109/ICRCICN50933.2020.9295964. URL <https://ieeexplore.ieee.org/document/9295964/>.
- Krishnan, S. R. y Kumar, T. A. A practical implementation smart farming using recommendation routing in wsn. *International Journal of Recent Technology and Engineering*, 2019(7):335–345, 2019.
- Kulkarni, S. S., Baghel, A. K., y Nayak, S. K. Square Slotted Patch Antenna for 2.45 GHz Far-field Wireless Power Transfer. In *2019 IEEE International Conference on Microwaves, Antennas, Communications and Electronic Systems (COMCAS)*, pages 1–4, Tel-Aviv, Israel, November 2019. IEEE. ISBN 9781538695494. doi: 10.1109/COMCAS44984.2019.8958143. URL <https://ieeexplore.ieee.org/document/8958143/>.
- Kulkarni, S. S., Baghel, A. K., y Nayak, S. K. Graded refractive index metamaterial for enhanced far-field wireless power transfer efficiency in S-band. *AEU - International Journal of Electronics and Communications*, 138:153859, August 2021. ISSN 14348411. doi: 10.1016/j.aeu.2021.153859. URL <https://linkinghub.elsevier.com/retrieve/pii/S1434841121002569>.
- Kumar, K. A., Krishna, A. V. N., y Shahu Chatrapati, K. Interference Minimization Protocol in Heterogeneous Wireless Sensor Networks for Military Applications. In Satapathy, S. C. y Das, S., editors, *Proceedings of First International Conference on Information and Communication Technology for Intelligent Systems: Volume 2*, volume 51, pages 479–487. Springer International Publishing, Cham, 2016. ISBN 9783319309262 9783319309279. doi: 10.1007/978-3-319-30927-9_47. URL http://link.springer.com/10.1007/978-3-319-30927-9_47.
- Lagarias, J. C., Reeds, J. A., Wright, M. H., y Wright, P. E. Convergence Properties of the Nelder–Mead Simplex Method in Low Dimensions. *SIAM Journal on Optimization*, 9(1):112–147, January 1998. ISSN 1052-6234, 1095-7189. doi: 10.1137/S1052623496303470. URL <http://epubs.siam.org/doi/10.1137/S1052623496303470>.
- Latino, M., Menegoli, M., y Corallo, A. Agriculture digitalization: A global examination based on bibliometric analysis. *IEEE Transactions on Engineering Management*, 2022. doi: 10.1109/TEM.2022.3154841.
- Leccisi, M., Cagnetti, M., Leccese, F., y Spagnolo, G. S. Comparing Routing Protocols for WSN in Agricultural Scenario. In *2021 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)*, pages 80–85, Trento-Bolzano, Italy, November 2021. IEEE. ISBN 9781665405331. doi: 10.1109/MetroAgriFor52389.2021.9628705. URL <https://ieeexplore.ieee.org/document/9628705/>.
- Lecun, Y. 1.1 deep learning hardware: Past, present, and future. volume 2019-February, pages 12–19, 2019. doi: 10.1109/ISSCC.2019.8662396.
- Lee, S.-R., Lim, E.-H., y Rahim, S. K. A. Small Wideband Antenna for On-Metal UHF RFID Tag Design. *IEEE Journal of Radio Frequency Identification*, 6:121–127, 2022. ISSN 2469-7281, 2469-729X. doi: 10.1109/JRFID.2021.3134492. URL <https://ieeexplore.ieee.org/document/9646237/>.

- Lehnert, J., Wübbeler, G., Kolbitsch, C., Chiribiri, A., Coquelin, L., Ebrard, G., Smith, N., Schaeffter, T., y Elster, C. Pixel-wise quantification of myocardial perfusion using spatial Tikhonov regularization. *Physics in Medicine & Biology*, 63(21):215017, October 2018. ISSN 1361-6560. doi: 10.1088/1361-6560/aae758. URL <https://iopscience.iop.org/article/10.1088/1361-6560/aae758>.
- Li, P., Peng, Y., y Wang, J. Propagation characteristics of 2.4 ghz radio wave in greenhouse of green peppers. 45:251–255, 01 2014. doi: 10.6041/j.issn.1000-1298.2014.02.042.
- Li, X., He, J., Huang, Y., Li, J., Liu, X., y Dai, J. Predicting the factors influencing construction enterprises' adoption of green development behaviors using artificial neural network. *Humanities and Social Sciences Communications*, 9(1), 2022. doi: 10.1057/s41599-022-01253-x.
- Li, Z., Wang, N., y Hong, T. Rf propagation patterns at 915 mhz and 2.4 ghz bands for in-field wireless sensor networks. *Transactions of the ASABE*, 56:787–796, 2013.
- Liu, H.-X., Yan, H.-L., Jia, N., Tang, S., Cong, D., Yang, B., Li, Z., Zhang, Y., Esling, C., Zhao, X., y Zuo, L. Machine-learning-assisted discovery of empirical rule for inherent brittleness of full heusler alloys. *Journal of Materials Science and Technology*, 131:1–13, 2022. doi: 10.1016/j.jmst.2022.05.017.
- Liu, J., Xie, J., Li, B., y Hu, B. Regularized Cubic B-Spline Collocation Method With Modified L-Curve Criterion for Impact Force Identification. *IEEE Access*, 8:36337–36349, 2020. ISSN 2169-3536. doi: 10.1109/ACCESS.2020.2973919. URL <https://ieeexplore.ieee.org/document/8999552/>.
- Liu, L., Hua, S., y Lai, Q. Automatic Control System of Balancing Agricultural Stereo Cultivation Based on Wireless Sensors. *IEEE Sensors Journal*, 21(16):17517–17524, August 2021a. ISSN 1530-437X, 1558-1748, 2379-9153. doi: 10.1109/JSEN.2021.3058100. URL <https://ieeexplore.ieee.org/document/9350644/>.
- Liu, X. y Wang, Y. An Improved Conjugate Gradient Image Reconstruction Algorithm for Electromagnetic Tomography. *Sensing and Imaging*, 23(1):5, December 2022. ISSN 1557-2064, 1557-2072. doi: 10.1007/s11220-021-00374-y. URL <https://link.springer.com/10.1007/s11220-021-00374-y>.
- Liu, X. A Survey on Clustering Routing Protocols in Wireless Sensor Networks. *Sensors*, 12(8):11113–11153, August 2012. ISSN 1424-8220. doi: 10.3390/s120811113. URL <http://www.mdpi.com/1424-8220/12/8/11113>.
- Liu, Y., Ma, X., Shu, L., Hancke, G., y Abu-Mahfouz, A. From industry 4.0 to agriculture 4.0: Current status, enabling technologies, and research challenges. *IEEE Transactions on Industrial Informatics*, 17(6):4322–4334, 2021b. doi: 10.1109/TII.2020.3003910.
- Luis Caparrós-Martínez, J., Rueda-Lópe, N., Milán-García, J., y de Pablo Valenciano, J. Public policies for sustainability and water security: The case of Almería (Spain). *Global Ecology and Conservation*, 23:e01037, September 2020. ISSN 23519894. doi: 10.1016/j.gecco.2020.e01037. URL <https://linkinghub.elsevier.com/retrieve/pii/S2351989420302250>.
- Lytaev, M. S. y Vladkyo, A. G. Split-step Padé Approximations of the Helmholtz Equation for Radio Coverage Prediction over Irregular Terrain. In *2018 Advances in Wireless and Optical Communications (RTUWO)*, pages 179–184, Riga, November 2018. IEEE. ISBN 9781538655580. doi: 10.1109/RTUWO.2018.8587886. URL <https://ieeexplore.ieee.org/document/8587886/>.
- Lyu, Z., Yu, Y., Samali, B., Rashidi, M., Mohammadi, M., Nguyen, T. N., y Nguyen, A. Back-Propagation Neural Network Optimized by K-Fold Cross-Validation for Prediction of Torsional Strength of Reinforced Concrete Beam. *Materials*, 15(4):1477, February 2022. ISSN 1996-1944. doi: 10.3390/ma15041477. URL <https://www.mdpi.com/1996-1944/15/4/1477>.
- López-Vilos, N., Valencia-Cordero, C., Azurdia-Meza, C., Montejo-Sánchez, S., y Mafra, S. B. Performance Analysis of the IEEE 802.15.4 Protocol for Smart Environments under Jamming Attacks. *Sensors*, 21(12):4079, June 2021. ISSN 1424-8220. doi: 10.3390/s21124079. URL <https://www.mdpi.com/1424-8220/21/12/4079>.
- Macave, O. A., Ribeiro, N. S., Ribeiro, A. I., Chaúque, A., Bandeira, R., Branquinho, C., y Washington-Allen, R. Modelling Aboveground Biomass of Miombo Woodlands in Niassa Special Reserve, Northern Mozambique. *Forests*, 13(2):311, February 2022. ISSN 1999-4907. doi: 10.3390/f13020311. URL <https://www.mdpi.com/1999-4907/13/2/311>.
- Madhumathi, R., Arumuganathan, T., y Shruthi, R. Internet of Things in Precision Agriculture: A Survey on Sensing Mechanisms, Potential Applications, and Challenges. In Raj, J. S., Palanisamy, R., Perikos, I., y Shi, Y., editors, *Intelligent Sustainable Systems*, volume 213, pages 539–553. Springer Singapore, Singapore, 2022. ISBN 9789811624216 9789811624223. doi: 10.1007/978-981-16-2422-3_42. URL https://link.springer.com/10.1007/978-981-16-2422-3_42.

- Mahajan, H. y Badarla, A. Cross-layer protocol for wsn-assisted iot smart farming applications using nature inspired algorithm. *Wireless Personal Communications*, 121(4):3125–3149, 2021a. doi: 10.1007/s11277-021-08866-6.
- Mahajan, H. B. y Badarla, A. Cross-Layer Protocol for WSN-Assisted IoT Smart Farming Applications Using Nature Inspired Algorithm. *Wireless Personal Communications*, 121(4):3125–3149, December 2021b. ISSN 0929-6212, 1572-834X. doi: 10.1007/s11277-021-08866-6. URL <https://link.springer.com/10.1007/s11277-021-08866-6>.
- Mahub, M. A smart farming concept based on smart embedded electronics, internet of things and wireless sensor network. *Internet of Things (Netherlands)*, 9, 2020. doi: 10.1016/j.iot.2020.100161.
- Mahesh, G., Balachander, D., y Rao, T. R. RF Propagation Measurements in Agricultural Fields for Wireless Sensor Communications. In *2013 International Conference on Circuits, Power and Computing Technologies (ICCPCT)*, pages 808–812, Nagercoil, March 2013. IEEE. ISBN 9781467349222 9781467349215 9781467349208. doi: 10.1109/ICCPCT.2013.6528846. URL <http://ieeexplore.ieee.org/document/6528846/>.
- Maiolo, L. y Polese, D. Advances in Sensing Technologies for Smart Monitoring in Precise Agriculture. In *Proceedings of the 10th International Conference on Sensor Networks*, pages 151–158, Vienna, Austria, 2021. SCITEPRESS - Science and Technology Publications. ISBN 9789897584893. doi: 10.5220/0010415401510158. URL <https://www.scitepress.org/DigitalLibrary/Link.aspx?doi=10.5220/0010415401510158>.
- Mamta y Prakash, S. An overview of healthcare perspective based security issues in wireless sensor networks. In *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, pages 870–875, 2016.
- Mancipe-Castro, L. y Gutiérrez-Carvajal, R. Prediction of environment variables in precision agriculture using a sparse model as data fusion strategy. *Information Processing in Agriculture*, 9(2):171–183, 2022. doi: 10.1016/j.inpa.2021.06.007.
- Mani, F. y Oestges, C. A Ray Based Method to Evaluate Scattering by Vegetation Elements. *IEEE Transactions on Antennas and Propagation*, 60(8):4006–4009, August 2012. ISSN 0018-926X, 1558-2221. doi: 10.1109/TAP.2012.2201123. URL <http://ieeexplore.ieee.org/document/6204058/>.
- Manríguez-Altamirano, A., Sierra-Pérez, J., Muñoz, P., y Gabarrell, X. Analysis of urban agriculture solid waste in the frame of circular economy: Case study of tomato crop in integrated rooftop greenhouse. *Science of The Total Environment*, 734:139375, September 2020. ISSN 00489697. doi: 10.1016/j.scitotenv.2020.139375. URL <https://linkinghub.elsevier.com/retrieve/pii/S0048969720328928>.
- Mao, Y., E, S., y Zhu, C. A New and Simple Design Method for End-Fire Dipole Antenna Array and Three Two-Element 24 GHz Planar End-Fire Dipole Antenna Arrays. *Applied Sciences*, 11(16):7720, August 2021. ISSN 2076-3417. doi: 10.3390/app11167720. URL <https://www.mdpi.com/2076-3417/11/16/7720>.
- Marsic, V., Kampert, E., y Higgins, M. D. Position Discrimination of a 2.4 GHz IEEE 802.15.4 RF Mobile Source Inside-Outside a Vehicle. In *2021 International Conference on Smart Applications, Communications and Networking (SmartNets)*, pages 1–6, Glasgow, United Kingdom, September 2021. IEEE. ISBN 9781665435451. doi: 10.1109/SmartNets50376.2021.9555414. URL <https://ieeexplore.ieee.org/document/9555414/>.
- Martin-Gorritz, B., Maestre-Valero, J., Gallego-Elvira, B., Marín-Membrive, P., Terrero, P., y Martínez-Alvarez, V. Recycling drainage effluents using reverse osmosis powered by photovoltaic solar energy in hydroponic tomato production: Environmental footprint analysis. *Journal of Environmental Management*, 297:113326, November 2021. ISSN 03014797. doi: 10.1016/j.jenvman.2021.113326. URL <https://linkinghub.elsevier.com/retrieve/pii/S0301479721013888>.
- Martínez-Valderrama, J., Guirado, E., y Maestre, F. T. Discarded food and resource depletion. *Nature Food*, 1(11):660–662, November 2020. ISSN 2662-1355. doi: 10.1038/s43016-020-00186-5. URL <http://www.nature.com/articles/s43016-020-00186-5>.
- Massa, D., Magán, J. J., Montesano, F. F., y Tzortzakis, N. Minimizing water and nutrient losses from soilless cropping in southern Europe. *Agricultural Water Management*, 241:106395, November 2020. ISSN 03783774. doi: 10.1016/j.agwat.2020.106395. URL <https://linkinghub.elsevier.com/retrieve/pii/S0378377420303589>.
- Matsuo, Y., LeCun, Y., Sahani, M., Precup, D., Silver, D., Sugiyama, M., Uchibe, E., y Morimoto, J. Deep learning, reinforcement learning, and world models. *Neural Networks*, 152:267–275, 2022. doi: 10.1016/j.neunet.2022.03.037.

- Mazzetto, F., Gallo, R., y Sacco, P. Reflections and methodological proposals to treat the concept of “information precision” in smart agriculture practices. *Sensors (Switzerland)*, 20(10), 2020. doi: 10.3390/s20102847.
- Meng, Y. S. y Lee, Y. H. INVESTIGATIONS OF FOLIAGE EFFECT ON MODERN WIRELESS COMMUNICATION SYSTEMS: A REVIEW. *Progress In Electromagnetics Research*, 105:313–332, 2010. ISSN 1559-8985. doi: 10.2528/PIER10042605. URL <http://www.jpier.org/PIER/pier.php?paper=10042605>.
- Mentsiev, A. U. y Gatina, F. F. Data analysis and digitalisation in the agricultural industry. *IOP Conference Series: Earth and Environmental Science*, 677(3):032101, March 2021. ISSN 1755-1307, 1755-1315. doi: 10.1088/1755-1315/677/3/032101. URL <https://iopscience.iop.org/article/10.1088/1755-1315/677/3/032101>.
- Mestre, P., Serodio, C., Morais, R., Azevedo, J., y Melo-Pinto, P. Vegetation growth detection using wireless sensor networks. *Lecture Notes in Engineering and Computer Science*, 1, 06 2010.
- Mestre, P., Ribeiro, J. G., Seródio, C., y Monteiro, J. L. Propagation of ieee802.15.4 in vegetation. In *Proceedings of the World Congress on Engineering 2011*, 2011.
- Miao, Y., Zhao, C., Wu, H., 1. College of Computer Science, Beijing University of Technology, Beijing 100124, China, 2. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China, y 3. Beijing Research Center for Information Technology in Agriculture, Beijing Academy of Agriculture and Forestry Sciences, Beijing, 100097, China. Non-uniform clustering routing protocol of wheat farmland based on effective energy consumption. *International Journal of Agricultural and Biological Engineering*, 14(3):142–150, 2021. ISSN 1934-6344. doi: 10.25165/j.ijabe.20211403.6540. URL <https://ijabe.org/index.php/ijabe/article/view/6540>.
- Mikeka, C., Thodi, M., Mlatho, J., Pinifolo, J., Kondwani, D., Momba, L., Zennaro, M., y More, A. Malawi television white spaces (tvws) pilot network performance analysis. *Journal of Wireless Networking and Communications*, 4:26–32, 01 2014. doi: 10.5923/j.jwnc.20140401.04.
- Militaru, L. G., Popescu, D., Mateescu, C., y Ichim, L. Correlation between Distance and Frequency Bands in Hybrid Air-Ground Sensor Networks. In *2018 5th International Conference on Control, Decision and Information Technologies (CoDIT)*, pages 247–252, Thessaloniki, Greece, April 2018. IEEE. ISBN 9781538650653. doi: 10.1109/CoDIT.2018.8394859. URL <https://ieeexplore.ieee.org/document/8394859/>.
- Mishra, C. y Gupta, D. Deep machine learning and neural networks: An overview. *IAES International Journal of Artificial Intelligence*, 6(2):66, 2017. doi: 10.11591/ijai.v6.i2.pp66-73.
- Mohsin, A., Alsmadi, Y., Arshad Uppal, A., y Gulfam, S. M. A modified simplex based direct search optimization algorithm for adaptive transversal FIR filters. *Science Progress*, 104(2):003685042110254, April 2021. ISSN 0036-8504, 2047-7163. doi: 10.1177/00368504211025409. URL <http://journals.sagepub.com/doi/10.1177/00368504211025409>.
- Montero, O., Pantoja, J. J., Patino, M., Pineda, E., Martinez, D., Angel, G., Cruz, J., Suarez, M., y Vega, F. Attenuation of Radiofrequency Waves due to Vegetation in Colombia. In *2018 IEEE-APS Topical Conference on Antennas and Propagation in Wireless Communications (APWC)*, pages 940–943, Cartagena des Indias, September 2018. IEEE. ISBN 9781538667651. doi: 10.1109/APWC.2018.8503671. URL <https://ieeexplore.ieee.org/document/8503671/>.
- Montero, O. R. y Araque, J. L. Approximate modeling of Electromagnetic Propagation through Vegetation. In *2018 IEEE-APS Topical Conference on Antennas and Propagation in Wireless Communications (APWC)*, pages 928–931, Cartagena des Indias, September 2018. IEEE. ISBN 9781538667651. doi: 10.1109/APWC.2018.8503668. URL <https://ieeexplore.ieee.org/document/8503668/>.
- Montoya, F., Gomez, J., Manzano-Agugliaro, F., Cama-Pinto, A., García-Cruz, A., y Cruz, J. 6lowsoft: A software suite for the design of outdoor environmental measurements. *Journal of Food, Agriculture and Environment*, 11:2584–2586, 01 2013.
- Moraitis, N., Tsipi, L., Vouyioukas, D., Gkioni, A., y Louvros, S. On the assessment of ensemble models for propagation loss forecasts in rural environments. *IEEE Wireless Communications Letters*, 11(5): 1097–1101, 2022. doi: 10.1109/LWC.2022.3157520.
- Mrabti, N., Mrabti, H., Khalil, Z., Bouyahya, A., Mohammed, E.-R., Dguigui, K., Doudach, L., Zengin, G., y Elhallaoui, M. Molecular docking and qsar studies for modeling the inhibitory activity of pyrazole-benzimidazolone hybrids as novel inhibitors of human 4-hydroxyphenylpyruvate dioxygenase against type i tyrosinemia disease. *Biointerface Research in Applied Chemistry*, 13(1), 2023. doi: 10.33263/BRIAC131.038.

- Mukherjee, S., Kim, D., y Lee, J. Base Station Coordination Scheme for Multi-Tier Ultra-Dense Networks. *IEEE Transactions on Wireless Communications*, 20(11):7317–7332, November 2021. ISSN 1536-1276, 1558-2248. doi: 10.1109/TWC.2021.3082625. URL <https://ieeexplore.ieee.org/document/9444152/>.
- Musaddiq, A., Rahim, T., y Kim, D.-S. Enhancing IEEE 802.15.4 Access Mechanism with Machine Learning. In *2021 Twelfth International Conference on Ubiquitous and Future Networks (ICUFN)*, pages 210–212, Jeju Island, Korea, Republic of, August 2021. IEEE. ISBN 9781728164762. doi: 10.1109/ICUFN49451.2021.9528725. URL <https://ieeexplore.ieee.org/document/9528725/>.
- Muthukumaran, S., Geetha, P., y Ramaraj, E. Multi-objective optimization with artificial neural network based robust paddy yield prediction model. *Intelligent Automation and Soft Computing*, 35(1):215–230, 2023. doi: 10.32604/iasc.2023.027449.
- Nasiri, A., Omid, M., Taheri-Garavand, A., y Jafari, A. Deep learning-based precision agriculture through weed recognition in sugar beet fields. *Sustainable Computing: Informatics and Systems*, 35, 2022. doi: 10.1016/j.suscom.2022.100759.
- Navarro, A., Guevara, D., y Florez, G. A. An Adjusted Propagation Model for Wireless Sensor Networks in Corn Fields. In *2020 XXXIIIrd General Assembly and Scientific Symposium of the International Union of Radio Science*, pages 1–3, Rome, Italy, August 2020. IEEE. ISBN 9789463968003. doi: 10.23919/URSIGASS49373.2020.9232365. URL <https://ieeexplore.ieee.org/document/9232365/>.
- Nawaz, A., Saleem, N., Mustafa, E., y Khan, U. An efficient global technique for solving network constrained static and dynamic economic dispatch problem. *Turkish Journal of Electrical Engineering and Computer Sciences*, 25:73–82, 01 2017. doi: 10.3906/elk-1503-236.
- Nazerian, M., Naderi, F., Partovinia, A., Papadopoulos, A. N., y Younesi-Kordkheili, H. Modeling the Bending Strength of MDF Faced, Polyurethane Foam-Cored Sandwich Panels Using Response Surface Methodology (RSM) and Artificial Neural Network (ANN). *Forests*, 12(11):1514, November 2021. ISSN 1999-4907. doi: 10.3390/f12111514. URL <https://www.mdpi.com/1999-4907/12/11/1514>.
- Ndzi, D. L., Harun, A., Ramli, F. M., Kamarudin, M. L., Zakaria, A., Shakaff, A. Y. M., Jaafar, M. N., Zhou, S., y Farook, R. S. Wireless sensor network coverage measurement and planning in mixed crop farming. *Computers and Electronics in Agriculture*, 105:83–94, July 2014. ISSN 01681699. doi: 10.1016/j.compag.2014.04.012. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168169914000945>.
- Nellore, K. y Hancke, G. A Survey on Urban Traffic Management System Using Wireless Sensor Networks. *Sensors*, 16(2):157, January 2016. ISSN 1424-8220. doi: 10.3390/s16020157. URL <http://www.mdpi.com/1424-8220/16/2/157>.
- Ngandu, G., Nomatungulula, C., Rimer, S., Paul, B. S., Ouahada, K., y Twala, B. Evaluating effect of foliage on link reliability of wireless signal. In *2013 IEEE International Conference on Industrial Technology (ICIT)*, pages 1528–1533, Cape Town, February 2013. IEEE. ISBN 9781467345699 9781467345675 9781467345682. doi: 10.1109/ICIT.2013.6505899. URL <http://ieeexplore.ieee.org/document/6505899/>.
- Ngo-Quynh, T., Tran-Quang, V., y Nguyen-Trung, Q. A low-latency communication protocol for target tracking in wireless sensor networks. *EURASIP Journal on Wireless Communications and Networking*, 2016(1):33, December 2016. ISSN 1687-1499. doi: 10.1186/s13638-016-0517-4. URL <https://jwcn-urasipjournals.springeropen.com/articles/10.1186/s13638-016-0517-4>.
- Nurwarsito, H. y Aziz, A. R. Implementation of the Friis Free Space Propagation Model in the Dynamic Source Routing (DSR) Routing Protocol in the Vehicular Ad-hoc Network (VANET) with Variations of Road Models. *Journal of Physics: Conference Series*, 1962(1):012063, July 2021. ISSN 1742-6588, 1742-6596. doi: 10.1088/1742-6596/1962/1/012063. URL <https://iopscience.iop.org/article/10.1088/1742-6596/1962/1/012063>.
- Obisesan, K. A., Neri, S., Bugnicourt, E., Campos, I., y Rodriguez-Turienzo, L. Determination and Quantification of the Distribution of CN-NL Nanoparticles Encapsulating Glycyrrhetic Acid on Novel Textile Surfaces with Hyperspectral Imaging. *Journal of Functional Biomaterials*, 11(2):32, May 2020. ISSN 2079-4983. doi: 10.3390/jfb11020032. URL <https://www.mdpi.com/2079-4983/11/2/32>.
- Okada, K. Millimeter-Wave CMOS Phased-Array Transceiver for 5G and Beyond. In *2020 IEEE International Electron Devices Meeting (IEDM)*, pages 34.3.1–34.3.4, San Francisco, CA, USA, December 2020. IEEE. ISBN 9781728188881. doi: 10.1109/IEDM13553.2020.9372045. URL <https://ieeexplore.ieee.org/document/9372045/>.
- Onofre, T. B., Fraise, C. W., McNair, J., Judge, J., Zotarelli, L., y Peres, N. A. Development of a Wireless Sensor Network for Field Level Strawberry Disease Alert Systems. *Applied Engineering in Agriculture*,

- 37(1):183–192, 2021. ISSN 1943-7838. doi: 10.13031/aea.13738. URL <https://elibrary.asabe.org/abstract.asp?AID=52032&t=3&dabs=Y&redir=&redirType=>.
- Orellana Figueroa, J., Reeves, J., McPherron, S., y Tennie, C. A proof of concept for machine learning-based virtual knapping using neural networks. *Scientific Reports*, 11(1), 2021. doi: 10.1038/s41598-021-98755-6.
- Oroza, C. A., Zhang, Z., Watteyne, T., y Glaser, S. D. A Machine-Learning-Based Connectivity Model for Complex Terrain Large-Scale Low-Power Wireless Deployments. *IEEE Transactions on Cognitive Communications and Networking*, 3(4):576–584, December 2017. ISSN 2332-7731. doi: 10.1109/TCNCN.2017.2741468. URL <http://ieeexplore.ieee.org/document/8013734/>.
- Ouafiq, E., Saadane, R., Chehri, A., y Jeon, S. Ai-based modeling and data-driven evaluation for smart farming-oriented big data architecture using iot with energy harvesting capabilities. *Sustainable Energy Technologies and Assessments*, 52, 2022. doi: 10.1016/j.seta.2022.102093.
- Oussama, C., Abdellah, E. A., Youssef, E. O., Mohammed, B., y Abdelkrim, O. In silico Prediction of Novel SARS-CoV 3CL pro Inhibitors: a Combination of 3D-QSAR, Molecular Docking, ADMET Prediction, and Molecular Dynamics Simulation. *Biointerface Research in Applied Chemistry*, 12(4):5100–5115, October 2021. ISSN 2069-5837. doi: 10.33263/BRIAC124.51005115. URL <https://biointerfaceresearch.com/wp-content/uploads/2021/10/20695837124.51005115.pdf>.
- Pal, J., Patra, K., y Gupta, B. Indoor Channel Characterisation and Modelling for 5G Applications at 22GHz. In *2019 IEEE 19th Mediterranean Microwave Symposium (MMS)*, pages 1–4, Hammamet, Tunisia, October 2019. IEEE. ISBN 9781728140643. doi: 10.1109/MMS48040.2019.9157298. URL <https://ieeexplore.ieee.org/document/9157298/>.
- Pal, P., Sharma, R. P., Tripathi, S., Kumar, C., y Ramesh, D. 2.4 GHz RF Received Signal Strength Based Node Separation in WSN Monitoring Infrastructure for Millet and Rice Vegetation. *IEEE Sensors Journal*, 21(16):18298–18306, August 2021. ISSN 1530-437X, 1558-1748, 2379-9153. doi: 10.1109/JSEN.2021.3083552. URL <https://ieeexplore.ieee.org/document/9440057/>.
- Park, W.-S. y Park, C.-S. Securing 6LoWPAN Neighbor Discovery. *IEEE Internet of Things Journal*, 8(17):13677–13689, September 2021. ISSN 2327-4662, 2372-2541. doi: 10.1109/JIOT.2021.3067591. URL <https://ieeexplore.ieee.org/document/9382376/>.
- Parlato, M. C., Valenti, F., y Porto, S. M. Covering plastic films in greenhouses system: A GIS-based model to improve post use sustainable management. *Journal of Environmental Management*, 263:110389, June 2020. ISSN 03014797. doi: 10.1016/j.jenvman.2020.110389. URL <https://linkinghub.elsevier.com/retrieve/pii/S0301479720303248>.
- Paul, B. S. y Rimer, S. A foliage scatter model to determine topology of wireless sensor network. In *2012 International Conference on Radar, Communication and Computing (ICRCC)*, pages 324–328, 2012. doi: 10.1109/ICRCC.2012.6450605.
- Pawgasame, W. A survey in adaptive hybrid wireless Sensor Network for military operations. In *2016 Second Asian Conference on Defence Technology (ACDT)*, pages 78–83, Chiang Mai, Thailand, January 2016. IEEE. ISBN 9781509022588. doi: 10.1109/ACDT.2016.7437647. URL <http://ieeexplore.ieee.org/document/7437647/>.
- Peng, Y., Xiao, Y., Fu, Z., Dong, Y., Zheng, Y., Yan, H., y Li, X. Precision irrigation perspectives on the sustainable water-saving of field crop production in China: Water demand prediction and irrigation scheme optimization. *Journal of Cleaner Production*, 230:365–377, September 2019. ISSN 09596526. doi: 10.1016/j.jclepro.2019.04.347. URL <https://linkinghub.elsevier.com/retrieve/pii/S0959652619314441>.
- Peng, Y., Knadel, M., Gislum, R., Schelde, K., Thomsen, A., y Greve, M. H. Quantification of SOC and Clay Content Using Visible Near-Infrared Reflectance–Mid-Infrared Reflectance Spectroscopy With Jack-Knifing Partial Least Squares Regression. *Soil Science*, 179(7):325–332, July 2014. ISSN 0038-075X. doi: 10.1097/SS.0000000000000074. URL <https://journals.lww.com/00010694-201407000-00001>.
- Petras, I. Tuning of the non-linear fractional-order controller. In *2019 20th International Carpathian Control Conference (ICCC)*, pages 1–4, Krakow-Wieliczka, Poland, May 2019. IEEE. ISBN 9781728107028. doi: 10.1109/CarpathianCC.2019.8765988. URL <https://ieeexplore.ieee.org/document/8765988/>.
- Pflanzner, T., Hovari, M., Vass, I., y Kertesz, A. Designing an iot-cloud gateway for the internet of living things. *Communications in Computer and Information Science*, 1218 CCIS:23–41, 2020. doi: 10.1007/978-3-030-49432-2_2.
- Pham, H. A New Criterion for Model Selection. *Mathematics*, 7(12):1215, December 2019. ISSN 2227-7390. doi: 10.3390/math7121215. URL <https://www.mdpi.com/2227-7390/7/12/1215>.

- Picallo, I., Klaina, H., Lopez-Iturri, P., Aguirre, E., Celaya-Echarri, M., Azpilicueta, L., Eguizábal, A., Falcone, F., y Alejos, A. A Radio Channel Model for D2D Communications Blocked by Single Trees in Forest Environments. *Sensors*, 19(21):4606, October 2019. ISSN 1424-8220. doi: 10.3390/s19214606. URL <https://www.mdpi.com/1424-8220/19/21/4606>.
- Pinna-Hernández, M. G., Fernández, F. G. A., Segura, J. G. L., y López, J. L. C. Solar Drying of Greenhouse Crop Residues for Energy Valorization: Modeling and Determination of Optimal Conditions. *Agronomy*, 10(12):2001, December 2020. ISSN 2073-4395. doi: 10.3390/agronomy10122001. URL <https://www.mdpi.com/2073-4395/10/12/2001>.
- Pisanu, T., Garau, S., Ortu, P., Schirru, L., y Macciò, C. Prototype of a low-cost electronic platform for real time greenhouse environment monitoring: An agriculture 4.0 perspective. *Electronics (Switzerland)*, 9(5), 2020. doi: 10.3390/electronics9050726.
- Piñeres-Espitia, G., Cama-Pinto, A., Estevez, F., Cama-Pinto, D., y Daniel, D. Design of a low cost weather station for detecting environmental changes. *Espacios*, 38:13, 12 2017.
- Popov, V. Cross-polarization effect of radio waves propagation by forest vegetation in wireless communication systems on transport. *Procedia Computer Science*, 149:195–201, 2019. ISSN 18770509. doi: 10.1016/j.procs.2019.01.123. URL <https://linkinghub.elsevier.com/retrieve/pii/S1877050919301309>.
- Preethichandra, D. Wireless sensor network for monitoring the health of healthcare facility environments. In *2015 9th International Conference on Sensing Technology (ICST)*, pages 50–53, Auckland, New Zealand, December 2015. IEEE. ISBN 9781479963140. doi: 10.1109/ICST.2015.7438363. URL <http://ieeexplore.ieee.org/document/7438363/>.
- Provencher, S. W. A constrained regularization method for inverting data represented by linear algebraic or integral equations. *Computer Physics Communications*, 27(3):213–227, September 1982a. ISSN 00104655. doi: 10.1016/0010-4655(82)90173-4. URL <https://linkinghub.elsevier.com/retrieve/pii/0010465582901734>.
- Provencher, S. W. CONTIN: A general purpose constrained regularization program for inverting noisy linear algebraic and integral equations. *Computer Physics Communications*, 27(3):229–242, September 1982b. ISSN 00104655. doi: 10.1016/0010-4655(82)90174-6. URL <https://linkinghub.elsevier.com/retrieve/pii/0010465582901746>.
- Qadir, Z., Khan, S. I., Khalaji, E., Munawar, H. S., Al-Turjman, F., Mahmud, M. P., Kouzani, A. Z., y Le, K. Predicting the energy output of hybrid PV–wind renewable energy system using feature selection technique for smart grids. *Energy Reports*, 7:8465–8475, November 2021. ISSN 23524847. doi: 10.1016/j.egy.2021.01.018. URL <https://linkinghub.elsevier.com/retrieve/pii/S2352484721000196>.
- Queiroz, D. V., Alencar, M. S., Gomes, R. D., Fonseca, I. E., y Benavente-Peces, C. Survey and systematic mapping of industrial Wireless Sensor Networks. *Journal of Network and Computer Applications*, 97: 96–125, November 2017. ISSN 10848045. doi: 10.1016/j.jnca.2017.08.019. URL <https://linkinghub.elsevier.com/retrieve/pii/S1084804517302771>.
- Raheemah, A., Sabri, N., Salim, M., Ehkan, P., Kamaruddin, R., Ahmad, R., Jaafar, M. N., Aljunid, S., y Chemat, M. H. Influences of parts of tree on propagation path losses for wsn deployment in greenhouse environments. 81:552–557, 11 2015.
- Raheemah, A., Sabri, N., Salim, M., Ehkan, P., y Ahmad, R. B. New empirical path loss model for wireless sensor networks in mango greenhouses. *Computers and Electronics in Agriculture*, 127:553–560, September 2016. ISSN 01681699. doi: 10.1016/j.compag.2016.07.011. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168169916304987>.
- Rahim, H. M., Leow, C. Y., y Rahman, T. A. Millimeter wave propagation through foliage: Comparison of models. In *2015 IEEE 12th Malaysia International Conference on Communications (MICC)*, pages 236–240, Kuching, Malaysia, November 2015. IEEE. ISBN 9781509000197. doi: 10.1109/MICC.2015.7725440. URL <http://ieeexplore.ieee.org/document/7725440/>.
- Rahim, H. M., Leow, C. Y., Rahman, T. A., Arsad, A., y Malek, M. A. Foliage attenuation measurement at millimeter wave frequencies in tropical vegetation. In *2017 IEEE 13th Malaysia International Conference on Communications (MICC)*, pages 241–246, Johor Bahru, November 2017. IEEE. ISBN 9781538631324. doi: 10.1109/MICC.2017.8311766. URL <http://ieeexplore.ieee.org/document/8311766/>.
- Rahman, N. Z. A., Tan, K. G., Omer, A., Rahman, T. A., y Reza, A. W. Radio Propagation Studies at 5.8 GHz for Point-to-Multipoint Applications Incorporating Vegetation Effect. *Wireless Personal Communications*, 72(1):709–728, September 2013. ISSN 0929-6212, 1572-834X. doi: 10.1007/s11277-013-1038-7. URL <http://link.springer.com/10.1007/s11277-013-1038-7>.

- Rahman, N. Z. A., Tan, K. G., Rahman, T. A., Idris, I. F. M., y Hamzah, N. A. A. Modeling of Dynamic Effect of Vegetation for Fixed Wireless Access System. *Wireless Personal Communications*, 96(1):1329–1354, September 2017. ISSN 0929-6212, 1572-834X. doi: 10.1007/s11277-017-4240-1. URL <http://link.springer.com/10.1007/s11277-017-4240-1>.
- Raich, P. y Kastner, W. A Computational Model for 6LoWPAN Multicast Routing. In *2021 17th IEEE International Conference on Factory Communication Systems (WFCS)*, pages 143–146, Linz, Austria, June 2021. IEEE. ISBN 9781665424783. doi: 10.1109/WFCS46889.2021.9483604. URL <https://ieeexplore.ieee.org/document/9483604/>.
- Raj, M., Gupta, S., Chamola, V., Elhence, A., Garg, T., Atiquzzaman, M., y Niyato, D. A survey on the role of internet of things for adopting and promoting agriculture 4.0. *Journal of Network and Computer Applications*, 187, 2021. doi: 10.1016/j.jnca.2021.103107.
- Rama Rao, T., Balachander, D., y Tiwari, N. Uhf short-range pathloss measurements in forest and plantation environments for wireless sensor networks. In *2012 IEEE International Conference on Communication Systems (ICCS)*, pages 194–198, 2012. doi: 10.1109/ICCS.2012.6406137.
- Rangwani, D., Sadhukhan, D., Ray, S., Khan, M. K., y Dasgupta, M. An improved privacy preserving remote user authentication scheme for agricultural wireless sensor network. *Transactions on Emerging Telecommunications Technologies*, 32(3), March 2021. ISSN 2161-3915, 2161-3915. doi: 10.1002/ett.4218. URL <https://onlinelibrary.wiley.com/doi/10.1002/ett.4218>.
- Rankine, C. J., Sanchez-Azofeifa, G. A., y MacGregor, M. H. Seasonal wireless sensor network link performance in boreal forest phenology monitoring. In *2014 Eleventh Annual IEEE International Conference on Sensing, Communication, and Networking (SECON)*, pages 302–310, Singapore, Singapore, June 2014. IEEE. ISBN 9781479946570. doi: 10.1109/SAHCN.2014.6990366. URL <http://ieeexplore.ieee.org/document/6990366/>.
- Ranzato, M., Hinton, G., y LeCun, Y. Guest editorial: Deep learning. *International Journal of Computer Vision*, 113(1):1–2, 2015. doi: 10.1007/s11263-015-0813-1.
- Rao, Y., Jiang, Z.-h., y Lazarovitch, N. Investigating signal propagation and strength distribution characteristics of wireless sensor networks in date palm orchards. *Computers and Electronics in Agriculture*, 124:107–120, June 2016. ISSN 01681699. doi: 10.1016/j.compag.2016.03.023. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168169916300928>.
- Rasmussen, C. E. y Williams, C. K. I. *Gaussian process for machine learning*. The MIT Press, 2006.
- Razafimandimby, C., Loscri, V., Vegni, A. M., y Neri, A. Efficient Bayesian Communication Approach for Smart Agriculture Applications. In *2017 IEEE 86th Vehicular Technology Conference (VTC-Fall)*, pages 1–5, Toronto, ON, September 2017. IEEE. ISBN 9781509059355. doi: 10.1109/VTCFall.2017.8288147. URL <http://ieeexplore.ieee.org/document/8288147/>.
- Richardson Ansah, M., Sowah, R. A., Melià-Seguí, J., Katsriku, F. A., Vilajosana, X., y Owusu Banahene, W. Characterising foliage influence on LoRaWAN pathloss in a tropical vegetative environment. *IET Wireless Sensor Systems*, 10(5):198–207, October 2020. ISSN 2043-6386, 2043-6394. doi: 10.1049/iet-wss.2019.0201. URL <https://onlinelibrary.wiley.com/doi/10.1049/iet-wss.2019.0201>.
- Ritika, Farooqui, N. A., y Tyagi, A. Data Mining and Fusion Techniques for Wireless Intelligent Sensor Networks. In Singh, P. K., Bhargava, B. K., Paprzycki, M., Kaushal, N. C., y Hong, W.-C., editors, *Handbook of Wireless Sensor Networks: Issues and Challenges in Current Scenario's*, volume 1132, pages 592–615. Springer International Publishing, Cham, 2020. ISBN 9783030403041 9783030403058. doi: 10.1007/978-3-030-40305-8_28. URL http://link.springer.com/10.1007/978-3-030-40305-8_28.
- Rogers, N., Seville, A., Richter, J., Ndzi, D., Savage, N., Caldeirinha, R., Shukla, A., Al-Nuaimi, M., Craig, K., Vilar, E., y Austin, J. A generic model of 1-60 ghz radio propagation through vegetation - final report. 03 2002.
- Roy, H. y Koley, S. Local-Friis-Radiation-Pattern (LFRP) for Face Recognition. *Sensing and Imaging*, 22(1):3, December 2021. ISSN 1557-2064, 1557-2072. doi: 10.1007/s11220-020-00325-z. URL <https://link.springer.com/10.1007/s11220-020-00325-z>.
- Roy, S. y Nene, M. J. A security framework for military application on infrastructure based wireless sensor network. In *2015 IEEE International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)*, pages 369–376, Kolkata, India, November 2015. IEEE. ISBN 9781467367356. doi: 10.1109/ICRCICN.2015.7434266. URL <http://ieeexplore.ieee.org/document/7434266/>.

- Rytel-Andrianik, R. Taper Design for Active Arrays With Maximized EIRP for Bounded Sidelobe Level. *IEEE Transactions on Antennas and Propagation*, 69(4):2053–2060, April 2021. ISSN 0018-926X, 1558-2221. doi: 10.1109/TAP.2020.3028225. URL <https://ieeexplore.ieee.org/document/9216516/>.
- Sabri, N., S, M. S., Fouad, S., A, S. A., Al-Dhief, F. T., y Raheemah, A. Investigation of Empirical Wave Propagation Models in Precision Agriculture. *MATEC Web of Conferences*, 150:06020, 2018. ISSN 2261-236X. doi: 10.1051/mateconf/201815006020. URL <https://www.matec-conferences.org/10.1051/mateconf/201815006020>.
- Sabri, N., Aljunid, S. A., Ahmad, R. B., Malek, M. F. A., Kamaruddin, R., y Salim, M. S. Wireless sensor network wave propagation in vegetation: Review and simulation. In *2012 Loughborough Antennas Propagation Conference (LAPC)*, pages 1–4, 2012. doi: 10.1109/LAPC.2012.6402994.
- Sabri, N., Aljunid, S. A., Salim, M. S., Kamaruddin, R., Ahmad, R. B., y Malek, M. F. Path Loss Analysis of WSN Wave Propagation in Vegetation. *Journal of Physics: Conference Series*, 423:012063, April 2013. ISSN 1742-6588, 1742-6596. doi: 10.1088/1742-6596/423/1/012063. URL <https://iopscience.iop.org/article/10.1088/1742-6596/423/1/012063>.
- Saeed, N., Alouini, M.-S., y Al-Naffouri, T. Y. Toward the Internet of Underground Things: A Systematic Survey. *IEEE Communications Surveys & Tutorials*, 21(4):3443–3466, 2019. ISSN 1553-877X, 2373-745X. doi: 10.1109/COMST.2019.2934365. URL <https://ieeexplore.ieee.org/document/8793165/>.
- Sagheer, A., Mohammed, M., Riad, K., y Alhajhoj, M. A cloud-based iot platform for precision control of soilless greenhouse cultivation. *Sensors (Switzerland)*, 21(1):1–29, 2021. doi: 10.3390/s21010223.
- Saiz-Rubio, V. y Rovira-Más, F. From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management. *Agronomy*, 10(2):207, February 2020. ISSN 2073-4395. doi: 10.3390/agronomy10020207. URL <https://www.mdpi.com/2073-4395/10/2/207>.
- Sakumura, C., Bettadpur, S., Save, H., y McCullough, C. High-frequency terrestrial water storage signal capture via a regularized sliding window mascon product from GRACE: GRACE RSWM. *Journal of Geophysical Research: Solid Earth*, 121(5):4014–4030, May 2016. ISSN 21699313. doi: 10.1002/2016JB012843. URL <http://doi.wiley.com/10.1002/2016JB012843>.
- Salim, C. y Mitton, N. K-predictions based data reduction approach in WSN for smart agriculture. *Computing*, 103(3):509–532, March 2021. ISSN 0010-485X, 1436-5057. doi: 10.1007/s00607-020-00864-z. URL <http://link.springer.com/10.1007/s00607-020-00864-z>.
- Sallehuddin, W. y Diab, A. Using Machine Learning to Predict the Fuel Peak Cladding Temperature for a Large Break Loss of Coolant Accident. *Frontiers in Energy Research*, 9:755638, October 2021. ISSN 2296-598X. doi: 10.3389/fenrg.2021.755638. URL <https://www.frontiersin.org/articles/10.3389/fenrg.2021.755638/full>.
- Sanjeevi, P., Prasanna, S., Siva Kumar, B., Gunasekaran, G., Alagiri, I., y Vijay Anand, R. Precision agriculture and farming using Internet of Things based on wireless sensor network. *Transactions on Emerging Telecommunications Technologies*, 31(12), December 2020. ISSN 2161-3915, 2161-3915. doi: 10.1002/ett.3978. URL <https://onlinelibrary.wiley.com/doi/10.1002/ett.3978>.
- Santoshkumar y Udaykumar R.Y. Development of WSN system for precision agriculture. In *2015 International Conference on Innovations in Information, Embedded and Communication Systems (ICIIECS)*, pages 1–5, Coimbatore, India, March 2015. IEEE. ISBN 9781479968176 9781479968183. doi: 10.1109/ICIIECS.2015.7192904. URL <http://ieeexplore.ieee.org/document/7192904/>.
- Sathish, C. y Srinivasan, K. An artificial bee colony algorithm for efficient optimized data aggregation to agricultural iot devices application. *Journal of Applied Science and Engineering*, 24:927–935, Juni 2021. ISSN 1560-6686. doi: 10.6180/jase.202112_24(6).0013. URL [https://doi.org/10.6180/jase.202112_24\(6\).0013](https://doi.org/10.6180/jase.202112_24(6).0013).
- Savage, N., Ndzi, D., Seville, A., Vilar, E., y Austin, J. Radio wave propagation through vegetation: Factors influencing signal attenuation: RADIO WAVE PROPAGATION THROUGH VEGETATION. *Radio Science*, 38(5):n/a–n/a, October 2003. ISSN 00486604. doi: 10.1029/2002RS002758. URL <http://doi.wiley.com/10.1029/2002RS002758>.
- Save, H., Bettadpur, S., y Tapley, B. D. Reducing errors in the GRACE gravity solutions using regularization. *Journal of Geodesy*, 86(9):695–711, September 2012. ISSN 0949-7714, 1432-1394. doi: 10.1007/s00190-012-0548-5. URL <http://link.springer.com/10.1007/s00190-012-0548-5>.
- Schantz, H. Introduction to ultra-wideband antennas. In *IEEE Conference on Ultra Wideband Systems and Technologies, 2003*, pages 1–9, Reston, Virginia, USA, 2003. IEEE. ISBN 9780780381872. doi: 10.1109/UWBST.2003.1267792. URL <http://ieeexplore.ieee.org/document/1267792/>.

- Schuhmacher, A., Hald, J., Rasmussen, K. B., y Hansen, P. C. Sound source reconstruction using inverse boundary element calculations. *The Journal of the Acoustical Society of America*, 113(1):114–127, January 2003. ISSN 0001-4966. doi: 10.1121/1.1529668. URL <http://asa.scitation.org/doi/10.1121/1.1529668>.
- Sen, Z., Sisman, E., y Kizilöz, B. A new innovative method for model efficiency performance. *Water Supply*, 22(1):589–601, January 2022. ISSN 1606-9749, 1607-0798. doi: 10.2166/ws.2021.245. URL <https://iwaponline.com/ws/article/22/1/589/83306/A-new-innovative-method-for-model-efficiency>.
- Seretis, A., Zhang, X., Zeng, K., y Sarris, C. Artificial neural network models for radiowave propagation in tunnels. *IET Microwaves, Antennas and Propagation*, 14(11):1198–1208, 2020. doi: 10.1049/iet-map.2019.0988.
- Sergeev, D. Classification of human actions using task fmri images. volume 2523, pages 395–403, 2019.
- Sern, C. C., Nasir, A. F. A., Abdul Majeed, A. P. P., Zakaria, M. A., Mohd Razman, M. A., y Azmi, A. Comparison of Support Vector Machine and Friis Equation For Identification of Pallet-Level Tagging Using RFID Signal. In *2020 IEEE 10th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, pages 215–219, Malaysia, April 2020. IEEE. ISBN 9781728150338. doi: 10.1109/ISCAIE47305.2020.9108834. URL <https://ieeexplore.ieee.org/document/9108834/>.
- Sert, S. A., Yazici, A., y Dokeroglu, T. Fuzzy processing in surveillance wireless sensor networks. In *2016 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, pages 1509–1515, Vancouver, BC, Canada, July 2016. IEEE. ISBN 9781509006267. doi: 10.1109/FUZZ-IEEE.2016.7737869. URL <http://ieeexplore.ieee.org/document/7737869/>.
- Shaik, M., Kabanni, A., y Nazeema, N. Millimeter wave propagation measurements in forest for 5G Wireless sensor communications. In *2016 16th Mediterranean Microwave Symposium (MMS)*, pages 1–4, Abu Dhabi, United Arab Emirates, November 2016. IEEE. ISBN 9781509025862. doi: 10.1109/MMS.2016.7803785. URL <http://ieeexplore.ieee.org/document/7803785/>.
- Sharma, H., Haque, A., y Blaabjerg, F. Machine Learning in Wireless Sensor Networks for Smart Cities: A Survey. *Electronics*, 10(9):1012, April 2021. ISSN 2079-9292. doi: 10.3390/electronics10091012. URL <https://www.mdpi.com/2079-9292/10/9/1012>.
- Sharma, S. y Mandal, P. A comprehensive report on machine learning-based early detection of alzheimer’s disease using multi-modal neuroimaging data. *ACM Computing Surveys*, 55(2), 2023. doi: 10.1145/3492865.
- Shaw, J. A. Radiometry and the Friis transmission equation. *American Journal of Physics*, 81(1):33–37, January 2013. ISSN 0002-9505, 1943-2909. doi: 10.1119/1.4755780. URL <http://aapt.scitation.org/doi/10.1119/1.4755780>.
- Shcherbakov, A. y Baramykov, M. The concept of agricultural complex based on agrivoltaics and precision agriculture. volume 949, 2022. doi: 10.1088/1755-1315/949/1/012127.
- Shehab, M. A. y Kahraman, N. Optimum, projected, and regularized extreme learning machine methods with singular value decomposition and l2-tikhonov regularization. *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES*, 26(4):1685–1697, jul 2018. doi: 10.3906/elk-1706-60. URL <https://doi.org/10.3906/elk-1706-60>.
- Sheikh-Hosseini, M. y Samareh Hashemi, S. R. Connectivity and coverage constrained wireless sensor nodes deployment using steepest descent and genetic algorithms. *Expert Systems with Applications*, 190:116164, March 2022. ISSN 09574174. doi: 10.1016/j.eswa.2021.116164. URL <https://linkinghub.elsevier.com/retrieve/pii/S095741742101486X>.
- Sheltami, T. R., Khan, S., Shakshuki, E. M., y Menshawi, M. K. Continuous objects detection and tracking in wireless sensor networks. *Journal of Ambient Intelligence and Humanized Computing*, 7(4):489–508, August 2016. ISSN 1868-5137, 1868-5145. doi: 10.1007/s12652-016-0380-5. URL <http://link.springer.com/10.1007/s12652-016-0380-5>.
- Shi, Y., Clare, S., y Vannesjo, S. J. Shim optimization with region of interest-specific Tikhonov regularization: Application to second-order slice-wise shimming of the brain. *Magnetic Resonance in Medicine*, 87(3):1218–1230, March 2022. ISSN 0740-3194, 1522-2594. doi: 10.1002/mrm.28951. URL <https://onlinelibrary.wiley.com/doi/10.1002/mrm.28951>.
- Short, S. M., Cogdill, R. P., y Anderson, C. A. Determination of figures of merit for near-infrared and raman spectrometry by net analyte signal analysis for a 4-component solid dosage system. *AAPS PharmSciTech*, 8(4):109–119, October 2007. ISSN 1530-9932. doi: 10.1208/pt0804096. URL <http://link.springer.com/10.1208/pt0804096>.

- Shue, S., Johnson, L. E., y Conrad, J. M. Utilization of XBee ZigBee modules and MATLAB for RSSI localization applications. In *SoutheastCon 2017*, pages 1–6, Concord, NC, USA, March 2017. IEEE. ISBN 9781538615393. doi: 10.1109/SECON.2017.7925305. URL <http://ieeexplore.ieee.org/document/7925305/>.
- Shutimarrungson, N. y Wuttidittachotti, P. Realistic propagation effects on wireless sensor networks for landslide management. *EURASIP Journal on Wireless Communications and Networking*, 2019(1):94, December 2019. ISSN 1687-1499. doi: 10.1186/s13638-019-1412-6. URL <https://jwcn-urasipjournals.springeropen.com/articles/10.1186/s13638-019-1412-6>.
- Song, X., Li, K., Dai, K., Wang, X., Du, H., y Zhao, H. A random-forest-assisted artificial-neural-network method for analysis of steel using laser-induced breakdown spectroscopy. *Optik*, 249:168214, January 2022. ISSN 00304026. doi: 10.1016/j.ijleo.2021.168214. URL <https://linkinghub.elsevier.com/retrieve/pii/S0030402621017447>.
- Sorri, K., Mustafee, N., y Seppänen, M. Revisiting iot definitions: A framework towards comprehensive use. *Technological Forecasting and Social Change*, 179, 2022. doi: 10.1016/j.techfore.2022.121623.
- Sosalagere, C., Adesegun Kehinde, B., y Sharma, P. Isolation and functionalities of bioactive peptides from fruits and vegetables: A reviews. *Food Chemistry*, 366:130494, January 2022. ISSN 03088146. doi: 10.1016/j.foodchem.2021.130494. URL <https://linkinghub.elsevier.com/retrieve/pii/S0308814621015004>.
- Sott, M., Nascimento, L., Foguesatto, C., Furstenu, L., Faccin, K., Zawislak, P., Mellado, B., Kong, J., y Bragazzi, N. A bibliometric network analysis of recent publications on digital agriculture to depict strategic themes and evolution structure. *Sensors*, 21(23), 2021. doi: 10.3390/s21237889.
- Srinivasan, P. y Jagatheeswari, P. Machine learning controller for dfig based wind conversion system. *Intelligent Automation and Soft Computing*, 35(1):381–397, 2023. doi: 10.32604/iasc.2023.024179.
- Srisooksai, T., Kaemarungsi, K., Takada, J., y Saito, K. Radio propagation measurement and characterization in outdoor tall food grass agriculture field for wireless sensor network at 2.4 ghz band. *Progress In Electromagnetics Research C*, 88:43–58, 2018. ISSN 1937-8718. doi: 10.2528/PIERC18062903. URL <http://www.jpier.org/PIERC/pier.php?paper=18062903>.
- Staudemeyer, R. C., Pöhls, H. C., y Wójcik, M. What it takes to boost Internet of Things privacy beyond encryption with unobservable communication: a survey and lessons learned from the first implementation of DC-net. *Journal of Reliable Intelligent Environments*, 5(1):41–64, April 2019. ISSN 2199-4668, 2199-4676. doi: 10.1007/s40860-019-00075-0. URL <http://link.springer.com/10.1007/s40860-019-00075-0>.
- Stewart, J., Stewart, R., y Kennedy, S. Internet of Things — Propagation modelling for precision agriculture applications. In *2017 Wireless Telecommunications Symposium (WTS)*, pages 1–8, Chicago, IL, USA, April 2017. IEEE. ISBN 9781509035991. doi: 10.1109/WTS.2017.7943528. URL <http://ieeexplore.ieee.org/document/7943528/>.
- Suman, S., Kumar, S., y De, S. Path Loss Model for UAV-Assisted RFET. *IEEE Communications Letters*, 22(10):2048–2051, October 2018. ISSN 1089-7798, 1558-2558, 2373-7891. doi: 10.1109/LCOMM.2018.2863389. URL <https://ieeexplore.ieee.org/document/8425706/>.
- Sumedha Sirsikir y Manoj Chandak. Energy-Efficient Self-organization Wireless Sensor Network for Traffic Management in Smart Cities. In Satapathy, S. C., Bhateja, V., y Joshi, A., editors, *Proceedings of the International Conference on Data Engineering and Communication Technology*, volume 468, pages 681–690. Springer Singapore, Singapore, 2017. ISBN 9789811016745 9789811016752. doi: 10.1007/978-981-10-1675-2_67. URL http://link.springer.com/10.1007/978-981-10-1675-2_67.
- Sun, Y., Bao, W., Jiang, P., Si, W., Zhou, J., y Zhang, Q. Development of a Regularized Dynamic System Response Curve for Real-Time Flood Forecasting Correction. *Water*, 10(4):450, April 2018. ISSN 2073-4441. doi: 10.3390/w10040450. URL <http://www.mdpi.com/2073-4441/10/4/450>.
- Suresh, P., Daniel, J., Parthasarathy, V., y Aswathy, R. A state of the art review on the internet of things (iot) history, technology and fields of deployment. 2014. doi: 10.1109/ICSEMR.2014.7043637.
- Suriano, L., Otero, A., Rodriguez, A., Sanchez-Renedo, M., y La Torre, E. D. Exploiting Multi-Level Parallelism for Run-Time Adaptive Inverse Kinematics on Heterogeneous MPSoCs. *IEEE Access*, 8: 118707–118724, 2020. ISSN 2169-3536. doi: 10.1109/ACCESS.2020.3005202. URL <https://ieeexplore.ieee.org/document/9126798/>.
- Swenson, S. C. y Wahr, J. M. Estimating signal loss in regularized GRACE gravity field solutions: Signal loss in regularized GRACE gravity fields. *Geophysical Journal International*, 185(2):693–702, May 2011. ISSN 0956540X. doi: 10.1111/j.1365-246X.2011.04977.x. URL <https://academic.oup.com/gji/article-lookup/doi/10.1111/j.1365-246X.2011.04977.x>.

- Tangdamrongsub, N., Hwang, C., Shum, C. K., y Wang, L. Regional surface mass anomalies from GRACE KBR measurements: Application of L-curve regularization and *a priori* hydrological knowledge. *Journal of Geophysical Research: Solid Earth*, 117(B11):n/a–n/a, November 2012. ISSN 01480227. doi: 10.1029/2012JB009310. URL <http://doi.wiley.com/10.1029/2012JB009310>.
- Tejada, G. M. G. y Reynoso, E. Q. D. Some guidelines to simulate wireless sensor networks in a propagation environment with non-uniform vegetation. *International Journal of Sensor Networks*, 17(1):40, 2015. ISSN 1748-1279, 1748-1287. doi: 10.1504/IJSNET.2015.067588. URL <http://www.inderscience.com/link.php?id=67588>.
- Tendulkar, A. *Introduction to precision agriculture: Overview, concepts, world interest, policy, and economics*. 2020. doi: 10.4018/978-1-7998-5000-7.ch001.
- Tesfay, T., Berhane, A., y Gebremariam, M. Optimizing Irrigation Water and Nitrogen Fertilizer Levels for Tomato Production. *The Open Agriculture Journal*, 13(1):198–206, December 2019. ISSN 1874-3315. doi: 10.2174/1874331501913010198. URL <https://openagriculturejournal.com/VOLUME/13/PAGE/198/>.
- Tewari, R., Swarup, S., y Roy, M. Radio wave propagation through rain forests of India. *IEEE Transactions on Antennas and Propagation*, 38(4):433–449, April 1990. ISSN 0018926X. doi: 10.1109/8.52261. URL <http://ieeexplore.ieee.org/document/52261/>.
- Thanakan, K., Sapphaniran, K., Palasarn, T., Supnithi, P., Phakphisut, W., y Sakorn, C. Real-Time Jamming Detection and Position Estimation via Software-Defined Radio (SDR). In *2021 18th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, pages 280–284, Chiang Mai, Thailand, May 2021. IEEE. ISBN 9781665403825. doi: 10.1109/ECTI-CON51831.2021.9454678. URL <https://ieeexplore.ieee.org/document/9454678/>.
- Ting, L., Man, Z., Yuhan, J., Sha, S., Yiqiong, J., y Minzan, L. Management of co₂ in a tomato greenhouse using wsn and bpnn techniques. *International Journal of Agricultural and Biological Engineering*, 8: 43–51, 2015.
- Tozzi, R., Masci, F., y Pezzopane, M. A stress test to evaluate the usefulness of Akaike information criterion in short-term earthquake prediction. *Scientific Reports*, 10(1):21153, December 2020. ISSN 2045-2322. doi: 10.1038/s41598-020-77834-0. URL <http://www.nature.com/articles/s41598-020-77834-0>.
- Tran, D. A., Tsujimura, M., Ha, N. T., Nguyen, V. T., Binh, D. V., Dang, T. D., Doan, Q.-V., Bui, D. T., Anh Ngoc, T., Phu, L. V., Thuc, P. T. B., y Pham, T. D. Evaluating the predictive power of different machine learning algorithms for groundwater salinity prediction of multi-layer coastal aquifers in the Mekong Delta, Vietnam. *Ecological Indicators*, 127:107790, August 2021. ISSN 1470160X. doi: 10.1016/j.ecolind.2021.107790. URL <https://linkinghub.elsevier.com/retrieve/pii/S1470160X21004556>.
- Tzounis, A., Katsoulas, N., Bartzanas, T., y Kittas, C. Internet of Things in agriculture, recent advances and future challenges. *Biosystems Engineering*, 164:31–48, December 2017. ISSN 15375110. doi: 10.1016/j.biosystemseng.2017.09.007. URL <https://linkinghub.elsevier.com/retrieve/pii/S1537511017302544>.
- Téllez, M., Cabello, T., Gámez, M., Burguillo, F., y Rodríguez, E. Comparative study of two predatory mites *Amblyseius swirskii* Athias-Henriot and *Traneisus montdorensis* (Schicha) by predator-prey models for improving biological control of greenhouse cucumber. *Ecological Modelling*, 431:109197, September 2020. ISSN 03043800. doi: 10.1016/j.ecolmodel.2020.109197. URL <https://linkinghub.elsevier.com/retrieve/pii/S0304380020302672>.
- Ullah, M., Narayanan, A., Wolff, A., y Nardelli, P. Unified framework to select an iot platform for industrial energy management systems. pages 950–955, 2021. doi: 10.23919/MIPRO52101.2021.9597128.
- Urnieszus, R., Kemesis, B., y Simutis, R. Bridging Offline Functional Model Carrying Aging-Specific Growth Rate Information and Recombinant Protein Expression: Entropic Extension of Akaike Information Criterion. *Entropy*, 23(8):1057, August 2021. ISSN 1099-4300. doi: 10.3390/e23081057. URL <https://www.mdpi.com/1099-4300/23/8/1057>.
- van den Biggelaar, A. J., Geluk, S. J., Jamroz, B. F., Williams, D. F., Smolders, A. B., Johannsen, U., y Bronckers, L. A. Accurate Gain Measurement Technique for Limited Antenna Separations. *IEEE Transactions on Antennas and Propagation*, 69(10):6772–6782, October 2021. ISSN 0018-926X, 1558-2221. doi: 10.1109/TAP.2021.3069583. URL <https://ieeexplore.ieee.org/document/9395383/>.
- Van Herbruggen, B., Jooris, B., Rossey, J., Ridolfi, M., Macoir, N., Van den Brande, Q., Lemey, S., y De Poorter, E. Wi-PoS: A Low-Cost, Open Source Ultra-Wideband (UWB) Hardware Platform with Long Range Sub-GHz Backbone. *Sensors*, 19(7):1548, March 2019. ISSN 1424-8220. doi: 10.3390/s19071548. URL <https://www.mdpi.com/1424-8220/19/7/1548>.

- Vanitha, V., Sangeerth Raj, C., Mithun Kumar, K., y Sebastian, J. Design and development of an effective smart garbage system using the internet of things. volume 2040, 2021. doi: 10.1088/1742-6596/2040/1/012033.
- Vaz, J. y Balaji, S. Convolutional neural networks (cnns): concepts and applications in pharmacogenomics. *Molecular Diversity*, 25(3):1569–1584, 2021. doi: 10.1007/s11030-021-10225-3.
- Vivek Raj, K., Dinesha, P., y Arpitha Shankar, S. I. Security Considerations in the Design of IEEE 802.15.4 Transceiver: A Review. In Khanna, K., Estrela, V. V., y Rodrigues, J. J. P. C., editors, *Cyber Security and Digital Forensics*, volume 73, pages 213–229. Springer Singapore, Singapore, 2022. ISBN 9789811639609 9789811639616. doi: 10.1007/978-981-16-3961-6_19. URL https://link.springer.com/10.1007/978-981-16-3961-6_19.
- Vougioukas, S., Anastassiou, H., Regen, C., y Zude, M. Influence of foliage on radio path losses (PLs) for wireless sensor network (WSN) planning in orchards. *Biosystems Engineering*, 114(4):454–465, April 2013. ISSN 15375110. doi: 10.1016/j.biosystemseng.2012.08.011. URL <https://linkinghub.elsevier.com/retrieve/pii/S1537511012001481>.
- Vu, T. Stanford university - coursera. https://github.com/tuanavu/coursera-stanford/commits/master/machine_learning/exercises/matlab/machine-learning-ex2/ex2/costFunctionReg.m, 2015.
- Vutukuri, A., Bhattacharya, S., Raj, T., Sridhar, y Geetha, V. Enhanced Back-Off Technique for IEEE 802.15.4 WSN Standard. In Meghanathan, N., Nagamalai, D., y Rajasekaran, S., editors, *Networks and Communications (NetCom2013)*, volume 284, pages 21–29. Springer International Publishing, Cham, 2014. ISBN 9783319036915 9783319036922. doi: 10.1007/978-3-319-03692-2_2. URL http://link.springer.com/10.1007/978-3-319-03692-2_2.
- Wahaishi, A. M. y Aburukba, R. Wireless sensor network smart environment for precision agriculture: An agent-based architecture. In Arai, K., editor, *Intelligent Systems and Applications*, pages 556–572, Cham, 2022. Springer International Publishing. ISBN 978-3-030-82193-7.
- Wang, F., Zhang, Z., Wang, G., Wang, Z., Li, M., Liang, W., Gao, J., Wang, W., Chen, D., Feng, Y., y Shi, G. Machine learning and theoretical analysis release the non-linear relationship among ozone, secondary organic aerosol and volatile organic compounds. *Journal of Environmental Sciences (China)*, 114:75–84, 2022. doi: 10.1016/j.jes.2021.07.026.
- Wang, J., Lin, J., y Xie, S. The environment monitoring system based on wireless sensor network. *Chinese Journal of Sensors and Actuators*, 28:1732–1740, 11 2015. doi: 10.3969/j.issn.1004-1699.2015.11.026.
- Wang, J., Peng, Y., y Li, P. Propagation Characteristics of Radio Wave in Plastic Greenhouse. In Li, D. y Li, Z., editors, *Computer and Computing Technologies in Agriculture IX*, volume 478, pages 208–215. Springer International Publishing, Cham, 2016. ISBN 9783319483566 9783319483573. doi: 10.1007/978-3-319-48357-3_20. URL http://link.springer.com/10.1007/978-3-319-48357-3_20.
- Wickramanayake, S., Hsu, W., y Lee, M. Comprehensible convolutional neural networks via guided concept learning. volume 2021-July, 2021. doi: 10.1109/IJCNN52387.2021.9534269.
- Widodo, S., Pratama, E. A., Pramono, S., y Basuki, S. B. Outdoor propagation modeling for wireless sensor networks 2.4 GHz. In *2017 IEEE International Conference on Communication, Networks and Satellite (Comnetsat)*, pages 158–162, Semarang, Indonesia, October 2017. IEEE. ISBN 9781538606506 9781538606520. doi: 10.1109/COMNETSAT.2017.8263592. URL <http://ieeexplore.ieee.org/document/8263592/>.
- Wolfe, P. Convergence conditions for ascent methods. *SIAM Review*, 11(2):226–235, April 1969. doi: 10.1137/1011036. URL <https://doi.org/10.1137/1011036>.
- Wong, T. W. Electrical, magnetic, photomechanical and cavitational waves to overcome skin barrier for transdermal drug delivery. *Journal of Controlled Release*, 193:257–269, November 2014. ISSN 01683659. doi: 10.1016/j.jconrel.2014.04.045. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168365914002788>.
- Wu, H., Miao, Y., Li, F., y Zhu, L. Empirical Modeling and Evaluation of Multi-Path Radio Channels on Wheat Farmland Based on Communication Quality. *Transactions of the ASABE*, 59(3):759–767, June 2016a. ISSN 21510032, 21510040. doi: 10.13031/trans.59.11016. URL <http://elibrary.asabe.org/abstract.asp?aid=46726&t=3&dabs=Y&redir=&redirType=>.
- Wu, H., Miao, Y., Li, F., y Zhu, L. Empirical Modeling and Evaluation of Multi-Path Radio Channels on Wheat Farmland Based on Communication Quality. *Transactions of the ASABE*, 59(3):759–767, June 2016b. ISSN 21510032, 21510040. doi: 10.13031/trans.59.11016. URL <http://elibrary.asabe.org/abstract.asp?aid=46726&t=3&dabs=Y&redir=&redirType=>.

- Xie, M., Wei, X., Tang, Y., y Hu, D. A Robust Design for Aperture-Level Simultaneous Transmit and Receive with Digital Phased Array. *Sensors*, 22(1):109, December 2021. ISSN 1424-8220. doi: 10.3390/s22010109. URL <https://www.mdpi.com/1424-8220/22/1/109>.
- Xu, Q., Li, R., Liu, Y., Luo, C., Xu, A., Xue, F., Xu, Q., y Li, X. Forecasting the Incidence of Mumps in Zibo City Based on a SARIMA Model. *International Journal of Environmental Research and Public Health*, 14(8):925, August 2017. ISSN 1660-4601. doi: 10.3390/ijerph14080925. URL <http://www.mdpi.com/1660-4601/14/8/925>.
- Xuanrong, P., Tingdong, Y., y Yuesheng, W. Research and design of precision irrigation system based on artificial neural network. In *2018 Chinese Control And Decision Conference (CCDC)*, pages 3865–3870, Shenyang, June 2018. IEEE. ISBN 9781538612446. doi: 10.1109/CCDC.2018.8407794. URL <https://ieeexplore.ieee.org/document/8407794/>.
- Yang, R. y Xing, B. A Comparison of the Performance of Different Interpolation Methods in Replicating Rainfall Magnitudes under Different Climatic Conditions in Chongqing Province (China). *Atmosphere*, 12(10):1318, October 2021. ISSN 2073-4433. doi: 10.3390/atmos12101318. URL <https://www.mdpi.com/2073-4433/12/10/1318>.
- Yang, S., Zhang, J., y Zhang, J. Impact of foliage on urban mmwave wireless propagation channel: A ray-tracing based analysis. In *2019 International Symposium on Antennas and Propagation (ISAP)*, pages 1–3, 2019.
- Yee Aung, S. M. y Kumar Pattanaik, K. Path Loss Measurement for Wireless Communication in Industrial Environments. In *2020 International Conference on Computer Science, Engineering and Applications (ICCSEA)*, pages 1–5, Gunupur, India, March 2020. IEEE. ISBN 9781728158303. doi: 10.1109/ICCSEA49143.2020.9132952. URL <https://ieeexplore.ieee.org/document/9132952/>.
- Yin Yap, X. y Seng Chia, K. A Portable Gas Pressure Control and Data Acquisition System using Regression Models. *International Journal on Electrical Engineering and Informatics*, 13(1):242–251, March 2021. ISSN 20856830, 20875886. doi: 10.15676/ijeie.2021.13.1.14. URL <http://ijeie.org/docs-2031767190606c2f087c220.pdf>.
- Yoon, S., Choi, J., Moon, S.-J., y Choi, J. H. Determination and quantification of heavy metals in sediments through laser-induced breakdown spectroscopy and partial least squares regression. *Applied Sciences*, 11(15):7154, August 2021a. doi: 10.3390/app11157154. URL <https://doi.org/10.3390/app11157154>.
- Yoon, S., Choi, J., Moon, S.-J., y Choi, J. H. Determination and Quantification of Heavy Metals in Sediments through Laser-Induced Breakdown Spectroscopy and Partial Least Squares Regression. *Applied Sciences*, 11(15):7154, August 2021b. ISSN 2076-3417. doi: 10.3390/app11157154. URL <https://www.mdpi.com/2076-3417/11/15/7154>.
- Yoshimura, R., Hara, M., Nishimura, T., Yamada, C., Shimasaki, H., Kado, Y., y Ichida, M. Effect of vegetation on radio wave propagation in 920-MHz and 2.4-GHz bands. In *2016 Asia-Pacific Microwave Conference (APMC)*, pages 1–4, New Delhi, India, December 2016. IEEE. ISBN 9781509015924. doi: 10.1109/APMC.2016.7931407. URL <http://ieeexplore.ieee.org/document/7931407/>.
- Yu, Q., Lyu, J., Jiang, L., y Li, L. Traffic Anomaly Detection Algorithm for Wireless Sensor Networks Based on Improved Exploitation of the GM(1,1) Model. *International Journal of Distributed Sensor Networks*, 12(7):2181256, July 2016. ISSN 1550-1477, 1550-1477. doi: 10.1177/155014772181256. URL <http://journals.sagepub.com/doi/10.1177/155014772181256>.
- Zakaria, Y., Ivanek, L., y and, I. G. Propagation measurements and estimation of channel propagation models in urban environment. *KSII Transactions on Internet and Information Systems*, 11(5):2453–2467, May 2017. doi: 10.3837/tiis.2017.05.008.
- Zapata-Sierra, A. J., Cama-Pinto, A., Montoya, F. G., Alcayde, A., y Manzano-Agugliaro, F. Wind missing data arrangement using wavelet based techniques for getting maximum likelihood. *Energy Conversion and Management*, 185:552–561, April 2019. ISSN 01968904. doi: 10.1016/j.enconman.2019.01.109. URL <https://linkinghub.elsevier.com/retrieve/pii/S0196890419301773>.
- Zennaro, M., Bagula, A., Gascon, D., y Noveleta, A. B. Long distance wireless sensor networks: simulation vs reality. In *Proceedings of the 4th ACM Workshop on Networked Systems for Developing Regions - NSDR '10*, pages 1–2, San Francisco, California, 2010. ACM Press. ISBN 9781450301930. doi: 10.1145/1836001.1836013. URL <http://portal.acm.org/citation.cfm?doid=1836001.1836013>.
- Zervopoulos, A., Tspis, A., Alvanou, A. G., Bezas, K., Papamichail, A., Vergis, S., Styliidou, A., Tsoumanis, G., Komianos, V., Koufoudakis, G., y Oikonomou, K. Wireless Sensor Network Synchronization for Precision Agriculture Applications. *Agriculture*, 10(3):89, March 2020. ISSN 2077-0472. doi: 10.3390/agriculture10030089. URL <https://www.mdpi.com/2077-0472/10/3/89>.

- Zhang, H. y Li, H. Node Localization Technology of Wireless Sensor Network Based on RSSI Algorithm. *International Journal of Online Engineering (iJOE)*, 12(10):51, October 2016. ISSN 1861-2121, 1868-1646. doi: 10.3991/ijoe.v12i10.6206. URL <http://online-journals.org/index.php/i-joe/article/view/6206>.
- Zhang, X., Wu, Y., y Wei, X. Localization algorithms in wireless sensor networks using nonmetric multidimensional scaling with rssi for precision agriculture. In *2010 The 2nd International Conference on Computer and Automation Engineering (ICCAE)*, volume 5, pages 556–559, 2010. doi: 10.1109/ICCAE.2010.5451282.
- Zhou, H., Qi, H., Banhazi, T. M., y Low, T. An Integrated WSN and Mobile Robot System for Agriculture and Environment Applications. In Stojmenovic, I., Cheng, Z., y Guo, S., editors, *Mobile and Ubiquitous Systems: Computing, Networking, and Services*, volume 131, pages 30–36. Springer International Publishing, Cham, 2014. ISBN 9783319115689 9783319115696. doi: 10.1007/978-3-319-11569-6_3. URL http://link.springer.com/10.1007/978-3-319-11569-6_3.
- Zolertia. Re-remote datasheet. *GitHub repository*, 2017. URL <https://github.com/Zolertia/Resources/wiki/RE-Mote>.
- Zuniga, M. y Krishnamachari, B. Analyzing the transitional region in low power wireless links. In *2004 First Annual IEEE Communications Society Conference on Sensor and Ad Hoc Communications and Networks, 2004. IEEE SECON 2004.*, pages 517–526, 2004. doi: 10.1109/SAHCN.2004.1381954.