



**UNIVERSIDAD ESTATAL PENÍNSULA  
DE SANTA ELENA  
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES  
INSTITUTO DE POSTGRADO**

**TÍTULO**

Optimización del enlace principal de radiocomunicación del Cuerpo de Bomberos de Cuenca en emergencias de gran magnitud mediante aprendizaje automático

**AUTORA**

**Gutiérrez Álvarez, Adriana Monserrath**

**TRABAJO DE TITULACIÓN**

Previo a la obtención del grado académico en  
**MAGÍSTER EN TELECOMUNICACIONES**

**TUTOR**

**Jaramillo Chamba, Daniel Armando**

**Santa Elena, Ecuador**

**Año 2025**



**UNIVERSIDAD ESTATAL PENÍNSULA  
DE SANTA ELENA  
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES  
INSTITUTO DE POSTGRADO  
TRIBUNAL DE SUSTENTACIÓN**

---

**Ing. Alicia Andrade Vera, Mgtr.  
COORDINADORA DEL  
PROGRAMA**

---

**Ing. Daniel Jaramillo Chamba, Mgtr.  
TUTOR**

---

**Ing. Lucrecia Llerena Guevara, Ph.D.  
DOCENTE  
ESPECIALISTA**

---

**Ing. Luis Amaya Fariño, Mgtr.  
DOCENTE  
ESPECIALISTA**

---

**Abg. María Rivera González, Mgtr.  
SECRETARIA GENERAL  
UPSE**



**UNIVERSIDAD ESTATAL PENÍNSULA  
DE SANTA ELENA  
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES  
INSTITUTO DE POSTGRADO**

**CERTIFICACIÓN**

Certifico que luego de haber dirigido científica y técnicamente el desarrollo y estructura final del trabajo, este cumple y se ajusta a los estándares académicos, razón por el cual apruebo en todas sus partes el presente trabajo de titulación que fue realizado en su totalidad por GUTIÉRREZ ÁLVAREZ, ADRIANA MONSERRATH como requerimiento para la obtención del título de Magíster en Telecomunicaciones.

**TUTOR**

---

**Ing. Daniel Jaramillo Chamba, Mgtr.**

**Santa Elena, 9 de octubre de 2025**



**UNIVERSIDAD ESTATAL PENÍNSULA  
DE SANTA ELENA  
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES  
INSTITUTO DE POSTGRADO**

**DECLARACIÓN DE RESPONSABILIDAD**

Yo, **ADRIANA MONSERRATH GUTIÉRREZ ÁLVAREZ**

**DECLARO QUE:**

El trabajo de Titulación, Optimización del enlace principal de radiocomunicación del Cuerpo de Bomberos de Cuenca en emergencias de gran magnitud mediante aprendizaje automático previo a la obtención del título en Magíster en Telecomunicaciones, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría.

En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

Santa Elena, 9 de octubre de 2025

**LA AUTORA**

---

Adriana Monserrath Gutiérrez Álvarez



**UNIVERSIDAD ESTATAL PENÍNSULA  
DE SANTA ELENA  
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES  
INSTITUTO DE POSTGRADO**

**CERTIFICACIÓN DE ANTIPLAGIO**

Certifico que después de revisar el documento final del trabajo de titulación denominado Optimización del enlace principal de radiocomunicación del Cuerpo de Bomberos de Cuenca en emergencias de gran magnitud mediante aprendizaje automático, presentado por el estudiante, GUTIÉRREZ ÁLVAREZ, ADRIANA MONSERRATH fue enviado al Sistema Antiplagio COMPILATIO, presentando un porcentaje de similitud correspondiente al 7%, por lo que se aprueba el trabajo para que continúe con el proceso de titulación.



**TUTOR**

**Ing. Daniel Jaramillo Chamba, Mgrtr.**



**UNIVERSIDAD ESTATAL PENÍNSULA  
DE SANTA ELENA  
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES  
INSTITUTO DE POSTGRADO**

**AUTORIZACIÓN**

Yo, **ADRIANA MONSERRATH GUTIÉRREZ ÁLVAREZ**

Autorizo a la Universidad Estatal Península de Santa Elena, para que haga de este trabajo de titulación o parte de él, un documento disponible para su lectura consulta y procesos de investigación, según las normas de la Institución.

Cedo los derechos en línea patrimoniales de mi Proyecto de titulación con componentes de investigación aplicada y/o de desarrollo con fines de difusión pública, además apruebo la reproducción de este proyecto de titulación con componentes de investigación aplicada y/o de desarrollo dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica y se realice respetando mis derechos de autor.

Santa Elena, 9 de octubre de 2025

**LA AUTORA**

---

**Adriana Monserrath Gutiérrez Álvarez**

## **AGRADECIMIENTO**

En primer lugar, agradezco a Dios por darme la fortaleza y la claridad necesaria para continuar en este camino académico, sosteniéndome en cada paso y permitiéndome alcanzar una meta más en mi vida.

Extiendo mi gratitud a la Universidad y, de manera especial, a los docentes y tutor, quienes con sus conocimientos y experiencias aportaron de manera significativa a mi formación. Sus enseñanzas han sido un apoyo esencial para el desarrollo de esta investigación y para mi crecimiento profesional y personal.

Finalmente, mi más sincero agradecimiento a mi familia, por su apoyo incondicional, su paciencia y la motivación constante que me han brindado. Sin su compañía y confianza, este logro no habría sido posible.

*Adriana Monserrath, Gutiérrez Álvarez*

## DEDICATORIA

A mi hija, porque es mi mayor inspiración y mi motivo para esforzarme cada día. Su alegría me ha dado la fuerza necesaria para culminar este camino, recordándome siempre que cada logro también es un regalo para ella.

A mi esposo, por ser mi compañero incondicional, por su paciencia, apoyo y comprensión en los momentos de mayor dedicación a este trabajo. Su confianza en mí ha sido un pilar fundamental para no rendirme y seguir adelante.

A mis padres, quienes con su ejemplo de esfuerzo y perseverancia me enseñaron el valor del trabajo y la importancia de la educación. Su cariño y respaldo constante han sido la base que me permitió alcanzar este objetivo académico y personal.

*Adriana Monserrath, Gutiérrez Álvarez*

# ÍNDICE GENERAL

TÍTULO .....	I
TRIBUNAL DE SUSTENTACIÓN.....	II
CERTIFICACIÓN .....	III
DECLARACIÓN DE RESPONSABILIDAD.....	IV
DECLARO QUE: .....	IV
CERTIFICACIÓN DE ANTIPLAGIO .....	V
AUTORIZACIÓN .....	VI
AGRADECIMIENTO .....	VII
DEDICATORIA .....	VIII
ÍNDICE GENERAL .....	IX
ÍNDICE DE TABLAS .....	XII
ÍNDICE DE FIGURAS .....	XIII
RESUMEN .....	XIV
ABSTRACT.....	XV
INTRODUCCIÓN .....	1
CAPÍTULO 1. MARCO TEÓRICO REFERENCIAL.....	5
1.1. Revisión de literatura .....	5
1.1.1. Diseño de un clasificador de calidad de enlaces inalámbricos basado en aprendizaje automático.....	5
1.1.2. Tecnología de radio en tiempo real y clasificación de modulación mediante un codificador automático LSTM. ....	6
1.1.3. Optimización de las comunicaciones D2D con aprendizaje automático en redes 5G.....	7
1.1.4. Revisión al Desarrollo de la Tecnología de Radio Cognitiva en Bandas VHF–UHF en el Ecuador.....	8

1.2. Desarrollo teórico y conceptual .....	8
1.2.1. Radiocomunicaciones en emergencias .....	8
1.2.2. Enlaces VHF: características y limitaciones.....	10
1.2.3. Problemas de cobertura y calidad del enlace .....	14
1.2.4. Aprendizaje automático aplicado a telecomunicaciones .....	20
1.2.5. Modelos de predicción de calidad de enlace .....	21
1.2.6. Aplicabilidad en el cantón Cuenca – contexto geográfico y operativo .....	23
1.2.7. Simulación de enlaces y entrenamiento de modelos .....	25
<b>CAPÍTULO 2. METODOLOGÍA .....</b>	<b>28</b>
2.1. Contexto de la investigación .....	28
2.2. Diseño y alcance de la investigación .....	30
2.3. Tipo y métodos de investigación.....	31
2.4. Población y muestra .....	32
2.5. Técnicas e instrumentos de recolección de datos.....	34
2.6. Procesamiento de la evaluación: Validez y confiabilidad de los instrumentos aplicados.....	35
<b>CAPÍTULO 3. RESULTADOS Y DISCUSIÓN .....</b>	<b>40</b>
3.1. Análisis del estado actual del enlace principal del sistema de radiocomunicación .....	40
3.1.1. Simulación del modelo Okumura-Hata en MATLAB.....	40
3.1.2. Simulación del modelo Longley-Rice en Radio Mobile .....	42
3.2. Diseño y entrenamiento del modelo predictivo .....	49
3.2.1. Definición de las variables del entorno.....	50
3.2.2. Generación de datos sintéticos.....	50
3.2.3. Entrenamiento de los Modelos en Python .....	51
3.3. Entrenamiento y validación del modelo de ML.....	57
3.4. Discusión de resultados.....	61

CONCLUSIONES .....	63
RECOMENDACIONES.....	64
REFERENCIAS.....	65
ANEXOS .....	72

## ÍNDICE DE TABLAS

Tabla 1.1: Impacto de cobertura, interferencia, programación en diferentes fenómenos	14
Tabla 1.2: Parámetros del enlace de radiofrecuencia .....	16
Tabla 1.3: Factores que afectan la señal en diferentes entornos .....	19
Tabla 2.1: Factores y niveles de simulación .....	30
Tabla 2.2: Tipos de zonas geográficas analizadas .....	33
Tabla 2.3: Tipo de eventos simulados .....	33
Tabla 3.1: Resultado de disponibilidad.....	48
Tabla 3.2: Resultado de variables de desempeño .....	49
Tabla 3.3: Variables a ser consideradas en modelo de optimización .....	50
Tabla 3.4: Comparación de desempeño y ventajas de los modelos aprendizaje .....	58
Tabla 3.5: Resultados de evaluación del sistema actual y modelo de optimización .....	60
Tabla 3.6: Resultados comparativos por escenario.....	60

## ÍNDICE DE FIGURAS

Figura 1.1: Reflexión, difracción y dispersión de señal .....	12
Figura 1.2: Interferencia de canal adyacente .....	13
Figura 1.3: Ubicación geográfica Cuenca.....	24
Figura 2.1: Diagrama de obtención de datos y evaluación de modelado. ....	37
Figura 2.2: Diagrama de estructura de resultados.....	38
Figura 3.1: Resultado de Modelo Okunura - Hata.....	41
Figura 3.2: Configuración de parámetros .....	43
Figura 3.3: Configuración de topología de red .....	43
Figura 3.4: Configuración de potencia. ....	44
Figura 3.5: Configuración de STRM para ubicación geográfica.....	44
Figura 3.6: Ubicación geográfica de Tx y Rx.....	45
Figura 3.7: Simulación de Rx_1 (rural) .....	45
Figura 3.8: Simulación de Rs_2 (zona montañosa) .....	46
Figura 3.9: Cobertura de Tx.....	46
Figura 3.10: Cobertura de Tx en google earth .....	47
Figura 3.11: Generación de registros sintéticos.....	51
Figura 3.12: Resultado de modelo de regresión lineal.....	52
Figura 3.13: Resultados de modelo Random Forest .....	54
Figura 3.14: Resultados de modelo SVM.....	56

## **RESUMEN**

Con el objetivo de optimizar la calidad y estabilidad del enlace principal de radiocomunicación VHF del Cuerpo de Bomberos de Cuenca durante emergencias de gran magnitud, en esta investigación se desarrolla y simula un modelo de aprendizaje automático predictivo. La metodología utilizada es cuantitativa y experimental, desarrollando simulaciones computacionales para un registro de datos sintéticos con variables de SNR, RSSI, potencia de transmisión, topografía, clima y obstáculos. Estos datos fueron entrenados y evaluados mediante modelos de aprendizaje como regresión lineal, random forest y SVM, empleando métricas de MSE, MAE y  $R^2$ .

Con el modelo de aprendizaje, los resultados obtenidos del sistema actual tienen una disponibilidad de 13.33% en zonas montañosas, mientras que con el modelo optimizado de random forest se tiene una disponibilidad de 73%. Con esto se concluye que el desarrollo de un modelo de aprendizaje automático es una solución efectiva y viable para que las comunicaciones en emergencias de gran magnitud sean estables y confiables.

Palabras claves: Emergencias, Aprendizaje automático, Radiocomunicación.

## **ABSTRACT**

To optimize the quality and stability of the Cuenca Fire Department's main VHF radio communication link during large-scale emergencies, this research develops and simulates a predictive machine learning model. The methodology used is quantitative and experimental, developing computational simulations for a synthetic data record with variables such as SNR, RSSI, transmission power, topography, weather, and obstacles. These data were trained and evaluated using learning models such as linear regression, random forest, and SVM, employing MSE, MAE, and  $R^2$  metrics.

With the learning model, the results obtained from the current system show an availability of 13.33% in mountainous areas, while the optimized random forest model shows an availability of 73%. This concludes that the development of a machine learning model is an effective and viable solution for stable and reliable communications in large-scale emergencies.

Keywords: Emergencies. Machine learning, Radio communication.

# INTRODUCCIÓN

En el contexto actual de gestión de emergencias, la eficiencia en las comunicaciones representa un pilar fundamental en la toma de decisiones y la coordinación oportuna en los equipos operativos de emergencias (Sienkiewicz-Małyjurek & Owczarek, 2020).

Cuenca es una ciudad que se distingue por su terreno irregular, variedad de climas y áreas de difícil acceso, lo que hace que asegurar la continuidad y la calidad de las radiocomunicaciones sea un desafío técnico, sobre todo para entidades como el Cuerpo de Bomberos del Cantón Cuenca, cuya tarea consiste en responder de manera rápida y eficaz a situaciones de gran envergadura como incendios en el bosque, deslizamientos, inundaciones o incidentes en áreas rurales.

Hoy en día, el sistema de radiocomunicación del BCBVC se maneja bajo una configuración fija en la banda VHF, esto limita en gran medida la adaptación a cambios rápidos en el entorno. Esto ocasiona áreas sin señal, reducción de cobertura y conexiones poco fiables en momentos decisivos. La falta de adaptabilidad del sistema actual muestra la necesidad de buscar soluciones de comunicación, incorporando sistemas automáticos que faciliten la gestión de manera más eficiente.

Durante el año 2024, el Benemérito Cuerpo de Bomberos Voluntarios de Cuenca atendió un total de 7078 emergencias, entre incendios estructurales, incendios forestales, emergencias médicas, rescates, inundaciones, siendo en este año considerablemente un incremento de incendios forestales por la sequía y eventos en zonas rurales.

En este contexto se identificaron zonas de cobertura deficiente en el sector del Cajas y Soldados, ubicados principalmente en parroquias rurales como Chaucha, Molleturo, donde se presentaron interrupciones frecuentes en la comunicación de voz por radio.

También, se identificaron incidentes técnicos que afectaron la coordinación de las unidades móviles y el centro de control, con fallas de enlace en momentos operativos. Esto demuestra que requerimos un sistema de radiocomunicaciones más robusto y adaptable, especialmente en desastres grandes, cuando la demora en la respuesta puede verse afectada por las comunicaciones.

Ante este problema, esta investigación plantea crear un modelo predictivo basado en métodos de aprendizaje automático que será aplicado mediante simulaciones computacionales para simular diferentes escenarios operacionales del Cuerpo de Bomberos de Cuenca.

Se busca que este modelo sea entrenado con datos simulados bajo condiciones reales del entorno cuencano incluyendo factores topográficos, meteorológicos y operativos, sea capaz de anticipar degradaciones en la calidad del enlace y ajustar dinámicamente los parámetros de transmisión para mantener la disponibilidad del sistema (Luna-Romero et al., 2025).

El enfoque planteado responde a una necesidad real del territorio; contar con soluciones de comunicación adaptativas, que no dependen exclusivamente del monitoreo humano o de ajustes manuales, sino que incorporan inteligencia artificial para actuar de forma autónoma y efectiva ante condiciones adversas.

El estudio propone un enfoque cuantitativo con énfasis en la experimentación. Utiliza herramientas especializadas como MATLAB, Python y Radio Mobile para crear el entorno simulado y comparar el rendimiento del sistema actual con el mejorado. Métricas importantes como la relación señal - ruido (SNR), la tasa de error de bit (BER) y la disponibilidad del enlace ayudarán a validar los hallazgos que analiza entornos urbanos, rurales y montañosos, así como eventos extremos comunes en la región andina del sur de Ecuador.

Los programas de MATLAB y Radio Mobile son útiles para crear, modelar, simular y examinar redes de telecomunicaciones complejas. Por otro lado, el lenguaje de programación Python al ser una plataforma gratuita y de código abierto es ideal para ejecutar técnicas de aprendizaje automático, entrenar modelos predictivos y automatizar el análisis de datos. Su amplia comunidad y disponibilidad de bibliotecas especializadas le convierten en una herramienta versátil para desarrollar aprendizaje automático requerido en la investigación. Y finalmente la herramienta de Radio Mobile es utilizada para la planificación de redes de radio, en esta plataforma se puede simular la cobertura y el rendimiento del sistema VHF, consideran la topografía real del terreno, los obstáculos y las condiciones de propagación de zonas montañosas como las del cantón Cuenca.

Desde el punto de vista tecnológico y científico, este estudio ayuda a generar ideas creativas en las telecomunicaciones que se usan en la gestión de desastres. Usar programas de inteligencia artificial en sistemas de radiocomunicación marca una ruptura con la forma tradicional de hacer las cosas, ya que demuestra que se pueden crear sistemas que aprenden y se adaptan en tiempo real sin necesidad de la intervención continua del operador.

Los efectos sociales de este esfuerzo son directos e importantes, ya que aumenta la capacidad operativa de una organización vital para la seguridad ciudadana. Además, se espera que los hallazgos obtenidos sirvan de guía para futuras aplicaciones en otras ciudades del país con entornos geográficos y operativos comparables, convirtiéndose en un modelo de comunicación resiliente y replicable para emergencias.

Este documento se organiza en tres capítulos. El Capítulo I presenta el marco teórico, describiendo los fundamentos de radiocomunicaciones, modelos de propagación y aprendizaje automático. El Capítulo II explica la metodología empleada, desde la obtención de las variables, hasta las herramientas y como se crearon los escenarios de simulación. En el Capítulo III se presentan y analizan los resultados comparando el sistema actual con el modelo propuesto. Por último, se presentan las conclusiones y recomendaciones para poner en práctica el modelo desarrollado.

### **Formulación del problema de investigación**

¿Cómo puede mejorarse la calidad y estabilidad del enlace principal del sistema de radiocomunicación del Cuerpo de Bomberos de Cuenca durante emergencias de gran magnitud, considerando las limitaciones topográficas, meteorológicas y técnicas del sistema actual?

### **Objetivo General:**

Desarrollar una simulación del radioenlace principal del sistema de radiocomunicación del Cuerpo de Bomberos Cuenca, utilizando herramientas informáticas y algoritmos de aprendizaje automático, para optimizar la calidad y estabilidad durante emergencias de gran magnitud.

### **Objetivos Específicos:**

1. Analizar el estado actual del enlace principal del sistema de radiocomunicación mediante el procesamiento de datos topográficos, geoespaciales y meteorológicos, con el fin de identificar las limitaciones técnicas y operativas.
2. Diseñar un modelo predictivo basado en algoritmos de inteligencia artificial mediante el entrenamiento supervisado de datos de transmisión simulados, para estimar el rendimiento del enlace y adaptar dinámicamente los parámetros.
3. Comparar el rendimiento del sistema de comunicación actual con el modelo optimizado propuesto, mediante simulaciones en emergencias de gran magnitud como incendios forestales, inundaciones, deslizamientos, con el fin de determinar mejoras en términos de cobertura, estabilidad y eficiencia operativa.

### **Planteamiento hipotético**

El uso de un modelo de aprendizaje automático, entrenado con datos simulados en diferentes condiciones topográficas y meteorológicas, permite optimizar la cobertura y estabilidad del radioenlace principal del sistema de radiocomunicación del Cuerpo de Bomberos de Cuenca, mejorando el tiempo de respuesta en situaciones de emergencia.

# CAPÍTULO 1. MARCO TEÓRICO REFERENCIAL

El presente capítulo desarrolla los fundamentos teóricos y conceptuales que sustentan esta investigación, abordando los principios de radiocomunicación aplicados en emergencias, los modelos de propagación VHF y las técnicas de aprendizaje automático utilizadas para optimizar la calidad y estabilidad del enlace principal.

## 1.1.Revisión de literatura

En esta sección se analiza un estudio que aplica técnicas de aprendizaje automático para estimar y clasificar la calidad de los enlaces inalámbricos, con el fin de comprender cómo estos modelos pueden emplearse en la optimización de redes de radiocomunicación.

### 1.1.1. Diseño de un clasificador de calidad de enlaces inalámbricos basado en aprendizaje automático.

Cerar, Yetgin, Mohorčič y Fortuna (2020) desarrollaron un estudio orientado al diseño de un clasificador de calidad de enlace inalámbrico (Link Quality Estimation, LQE) utilizando algoritmos de aprendizaje automático. El objetivo fue analizar, de forma integral, cómo diversas decisiones de diseño, como el preprocesamiento de datos, la ingeniería de características, el tamaño de las ventanas de observación y las estrategias de remuestreo, afectan el rendimiento general del modelo.

Para llevar a cabo la experimentación, Cerar (2020) utilizó un conjunto de datos que incluía 4.060 trazas de enlaces inalámbricos, todas recolectadas en un entorno controlado, cada traza contenía 300 paquetes que se transmitían cada 100 milisegundos, y se probó bajo diferentes niveles de interferencia artificial, que iban desde 0 hasta -20 dBm. Este conjunto de datos abarcaba variables como el RSSI, identificadores de nodos y niveles de ruido, y presentaba condiciones desafiantes, como un 23,6 % de enlaces vacíos y un 63,5 % de recepción promedio de paquetes.

La metodología se basó en el enfoque KDD (*Knowledge Discovery in Databases*), que se organiza en cinco etapas: limpieza e interpolación de datos, ingeniería de características, selección de ventanas temporales, remuestreo de clases y comparación de

algoritmos de clasificación. Esta estructura facilitó la identificación del impacto de cada fase en la precisión final del modelo.

En este estudio es importante como se realiza el procesamiento, utiliza la técnica de sustituir los valores faltantes por ceros, permitiendo elevar la precisión hasta un 95,2 %. Esto indica que, en entornos de datos incompletos, el manejo de la información previa al entrenamiento del modelo es tan importante como la elección del algoritmo. También, se evidenció problemas de desbalance de clases en el dataset (61 % de enlaces buenos, 34 % malos y solo 5 % intermedios), situación común en escenarios reales, donde los enlaces críticos suelen ser los menos representados.

La inclusión de atributos derivados del RSSI, como el promedio y la desviación estándar, ha permitido una mejora notable en la detección de enlaces intermedios, pasando del 38 % al 87 %.

Este estudio se considera para la investigación porque permite predecir el rendimiento de los enlaces utilizando técnicas de: creación de características, balanceo de tipo y evaluación mediante ventanas periódicas. Esto permite predecir el rendimiento de los enlaces y anticipar zonas con baja cobertura, aspectos necesarios a considerar en tiempos de respuesta en situaciones de emergencia.

### **1.1.2. Tecnología de radio en tiempo real y clasificación de modulación mediante un codificador automático LSTM.**

Ke y Vikalo (2020), desarrollaron un modelo de aprendizaje automático con autocodificadores LSTM *denoising*. El modelo sirve para clasificar señales de radio que tienen ruido e interferencias, logrando identificar el tipo de modulación o tecnología de comunicación directamente desde señales IQ (fase y amplitud), aunque la señal no esté muy clara.

El modelo se compone de un autocodificador LSTM de dos capas, entrenado junto con un clasificador *softmax*. Cumple dos funciones (1) reconstruye señales corrompidas, y (2) clasifica las señales reconstruidas usando representaciones comprimidas del último estado de la red LSTM. Durante el entrenamiento, se introdujo ruido artificial (*denoising*) para hacer el modelo más robusto.

Se utilizaron tres bases de datos:

- “RadioML2016.10A (modulaciones sintéticas),
- RadioML2018.01A (con ruido térmico y desincronización),
- Electrosense (datos reales del espectro).”

La optimización se realizó con el algoritmo Adam, y se empleó una función de pérdida combinada que equilibra precisión de reconstrucción y clasificación. En los experimentos, el modelo superó en precisión a otros métodos como CNN, CLDNN y redes residuales, especialmente con SNR entre 0 y 30 dB.

Además, demostró buen rendimiento sobre datos reales (Electrosense), diferenciando tecnologías similares como DVB y LTE. Su arquitectura compacta permite clasificación en tiempo real, lo que lo hace viable para dispositivos de bajo costo.

Este enfoque resulta útil para entornos donde los recursos son limitados, como redes de emergencia en zonas rurales o montañosas. Aplicarlo al sistema de radiocomunicación del BCBVC permitiría detectar enlaces inestables y realizar ajustes automáticos, mejorando la cobertura y estabilidad durante emergencias.

### **1.1.3. Optimización de las comunicaciones D2D con aprendizaje automático en redes 5G**

Deng et al. (2024) presentaron una propuesta basada en inteligencia artificial para optimizar las comunicaciones dispositivo a dispositivo (D2D) en redes móviles de quinta generación. El objetivo fue diseñar un sistema que permita a los dispositivos decidir de manera autónoma cuándo y cómo reutilizar los recursos del espectro, garantizando calidad de servicio y eficiencia en escenarios con alta densidad de usuarios.

En este trabajo combinaron el aprendizaje profundo y aprendizaje por refuerzo. Cada punto aprendió a modificar sus parámetros como la potencia de transmisión a través mediante la interacción con su entorno.

El sistema analizó los datos en tiempo real para asignar recursos y minimizar el impacto en los usuarios de la red celular convencional, con esto se obtuvo que el modelo propuesto mejore la eficiencia espectral de la red, la tasa de éxito incremento en

conexiones D2D sin comprometer la calidad del servicio celular, logrando reducir la interferencia entre usuarios. Este análisis se puede utilizar en la investigación del Cuerpo de Bomberos de Cuenca, sobre todo en las parroquias rurales o lugares de difícil acceso, donde la construcción de infraestructura de comunicación es limitada.

#### **1.1.4. Revisión al Desarrollo de la Tecnología de Radio Cognitiva en Bandas VHF–UHF en el Ecuador**

Vega León (2020) revisó el desarrollo de la radio cognitiva en bandas VHF–UHF en Ecuador, destacando la ausencia de implementaciones concretas de redes cognitivas o reutilización espectral en entornos montañosos y rurales. Esta situación evidencia una clara oportunidad de investigación para adaptar modelos de estimación de calidad de enlace (LQE) y técnicas de optimización que respondan a la topografía regional.

En el país hay mucho interés por las tecnologías de radiocomunicación, pero no hay estudios sobre cómo aplicar modelos de propagación y cálculo de calidad de enlace en entornos montañosos, por lo que un desafío para instituciones como el Cuerpo de Bomberos de Cuenca, que dependen de enlaces VHF confiables para sus labores diarias.

Este trabajo es importante porque propone soluciones basadas en aprendizaje automático considerando variables como la vegetación, la difracción y el clima. El objetivo es mejorar la predicción de la calidad del enlace y garantizar comunicaciones más seguras y efectivas en situaciones de emergencia.

### **1.2.Desarrollo teórico y conceptual**

En esta sección se presentan los fundamentos teóricos y conceptos esenciales que sustentan la investigación

#### **1.2.1. Radiocomunicaciones en emergencias**

Las telecomunicaciones constituyen un pilar fundamental en la gestión de riesgos y desastres, al permitir la transmisión eficiente de información crítica durante todas las fases del manejo de emergencias, desde la alerta temprana hasta la rehabilitación. Esta

infraestructura posibilita la coordinación entre instituciones, la movilización de recursos y la difusión de mensajes a la población afectada (Oladele, 2024).

En este sentido, la conectividad entre organismos de primera respuesta, autoridades gubernamentales y ciudadanía resulta indispensable para la toma de decisiones oportunas en contextos de alta incertidumbre y urgencia (Wang et al., 2023). En el caso de Ecuador, el Plan Nacional de Respuesta ante Desastres reconoce que la eficiencia del Sistema Nacional Descentralizado de Gestión de Riesgos depende en gran medida de la articulación interinstitucional mediante mecanismos de comunicación claros, confiables y estandarizados.

En caso de desastres naturales, los sistemas de radiocomunicación deben estar siempre disponibles, deben ser fiables y tener buena cobertura. Para lograr esto, las redes de comunicación de emergencia incluyen características específicas como redundancia, resistencia a interferencias y escalabilidad dinámica, garantizando la continuidad del servicio cuando las redes tradicionales fallan.

En el país, el Plan Nacional de Respuesta ante Desastres menciona la importancia de establecer una infraestructura tecnológica simple pero sólida, que se pueda adaptar a instalaciones existentes o improvisadas, facilitando así la toma de decisiones y optimizando los recursos durante la respuesta. Las instituciones de primera respuesta a emergencias deben seguir directrices que exigen el uso de medios de comunicación confiables, como redes de radio, para asegurar una intervención efectiva en las áreas afectadas (*Plan Nacional de Respuestas - Secretaria de Gestión de Riesgos, 2025*).

La Unión Internacional de Telecomunicaciones (UIT), es la institución a nivel internacional que resalta que las telecomunicaciones en situaciones de emergencia deben ser consideradas infraestructura crítica, porque su funcionamiento debe garantizarse antes, durante y después de una catástrofe. La UIT también promueve marcos regulatorios que garanticen la continuidad de los servicios de comunicación y el uso preferente del espectro radioeléctrico por parte de los servicios de emergencia (*Comisiones de estudio de radiocomunicaciones del UIT-R, 2020*).

### **1.2.2. Enlaces VHF: características y limitaciones**

La banda VHF (Very High Frequency) comprende el espectro de frecuencias entre 30 MHz y 300 MHz, dentro del cual se incluyen varios servicios de radiocomunicación como televisión analógica, radio FM, comunicaciones aeronáuticas, marítimas y servicios de seguridad pública. En particular, las comunicaciones móviles terrestres y los sistemas de radiocomunicación institucional suelen operar en el rango de 136 MHz a 174 MHz. Esto se debe a que es una franja relativamente despejada de congestión y ofrece una buena combinación de cobertura, penetración y robustez.

Una de las grandes ventajas de la banda VHF es su capacidad de propagación en línea de vista directa, lo que permite lograr coberturas efectivas en distancias de entre 30 y 50 kilómetros, siempre que se utilicen antenas adecuadamente elevadas. Esta propagación es menos afectada por obstáculos pequeños en comparación con frecuencias más altas, pero sí puede experimentar pérdidas al atravesar grandes estructuras o accidentes geográficos como montañas. (Wang et al., 2024)

Otra característica importante es que puede operar con baja potencia, lo que permite a los equipos portátiles ampliar su autonomía. Sin embargo VHF es más sensible a la interferencia creada por otros servicios vecinos si no regula un correcto plan de frecuencias y separación de canales.

Investigaciones recientes, indican que el uso de señales VHF son un respaldo para sistemas de temporización críticos, reemplazando sistemas dependientes del GNSS (Global Navigation Satellite System). Este respaldo se puede lograr utilizando señales de oportunidad (SoOp) para sincronización de la señal distribuyendo a lo largo de grandes áreas geográficas (Olkkonen et al., 2025).

El sistema VHF es el principal medio de comunicación para situaciones operativas y de emergencia del Cuerpo de Bomberos de Cuenca. Tiene 7 repetidoras, ubicadas estratégicamente en las zonas más altas del cantón Cuenca, lo que lo permite mantener la conectividad durante las emergencias y coordinar las operaciones en tiempo real.

## *Ventajas y desventajas del uso de VHF en zonas rurales o montañosas*

### *Ventajas:*

- Cobertura regional eficiente: La propagación de señales VHF permite alcanzar distancias considerables en línea de vista, lo que es útil en zonas de difícil acceso como áreas rurales o montañosas (Al-Zubi & Alouini, 2023).
- VHF presenta menor susceptibilidad al ruido urbano a diferencia de otras bandas como UHF.
- La implementación de redes VHF son menos costosas, que las infraestructuras de las redes móviles y satelitales.
- Organizaciones privadas y públicas utilizan sistemas VHF para operaciones logísticas, despacho de emergencias y para el mantenimiento.

### *Desventajas:*

- Limitada penetración de obstáculos: Las señales VHF pueden experimentar pérdidas cuando deben atravesar colinas, edificaciones densas o vegetación espesa. (Wang et al., pag. 29)
- Dependencia de línea de vista: En terrenos abruptos o montañosos, la calidad de la comunicación puede verse afectada si no se dispone de una infraestructura de repetición adecuada.
- Congestión del espectro: En zonas costeras o de alta actividad institucional, el espectro VHF puede saturarse, generando problemas e interferencias de señal (Wang et al., pag.26).
- Baja capacidad de datos: Las tecnologías VHF están limitadas en cuanto al ancho de banda, por lo que su uso es principalmente para voz o mensajes de texto estructurados.

### *Limitaciones en cobertura, interferencia y propagación*

#### *Cobertura*

La cobertura de un sistema VHF está determinada por múltiples factores:

- **Altura de antenas y topografía:** en VHF las ondas viajan línea de vista, por lo que su alcance está limitado por la forma de la Tierra y puede ser bloqueada por montañas, colinas o edificios. Si las antenas están lo suficientemente altas la comunicación puede tener una cobertura de hasta 160 Km. Sin embargo, en terrenos montañosos, las señales pueden quedar "en sombra" detrás de obstáculos, por lo que es necesario instalar repetidoras en puntos elevados para poder cubrir valles que de otro modo serían inaccesibles (véase Figura 1.1 ).




Figura 1.1: Reflexión, difracción y dispersión de señal

Fuente: (Kornr, 2025).

- **Clima y troposfera:** fenómenos meteorológicos como las inversiones térmicas pueden curvar las ondas VHF, extendiendo temporalmente el alcance más allá del horizonte normal, aunque también generando interferencias con canales distantes. Condiciones como lluvia intensa, nieve o alta humedad provocan atenuación, reduciendo la calidad de la comunicación.

### ***Interferencia***

- **Interferencia co-canal (CCI):** ocurre cuando dos transmisores utilizan la misma frecuencia. Incluso con planificación geográfica, las condiciones atmosféricas pueden intensificar la propagación y causar superposición de señales.

- Interferencia de canal adyacente: se produce por filtrado insuficiente o separación inadecuada entre canales, lo que genera fugas y degrada el rendimiento del receptor (ver Figura 1.2)




Figura 1.2: Interferencia de canal adyacente

Fuente: (Co-Channel and Adjacent Channel Interference in Mobile Computing, 2023).

- Interferencias electromagnéticas (EMI): los equipos eléctricos cercanos (motores, líneas de alta tensión, generadores) generan ruido que disminuye la relación señal-ruido. Asimismo, el ruido atmosférico, especialmente durante tormentas eléctricas, puede causar estática significativa.
- Spoofing y jamming: en aplicaciones críticas, como comunicaciones marítimas y de emergencia, se han identificado ataques que alteran la integridad de los datos, comprometiendo la seguridad operacional.

### ***Propagación:***

Las señales VHF se propagan principalmente en línea recta, pero también pueden reflejarse o refractarse dependiendo del entorno. Factores como la reflexión en superficies metálicas, el efecto de multitrayectoria (*multipath*) y las variaciones atmosféricas pueden alterar la fidelidad de la señal. Olkkonen et al. (2025) destacan que, para sistemas críticos como redes eléctricas, donde se necesita sincronización precisa, estas distorsiones deben ser mitigadas con algoritmos de calibración diferencial entre receptores remotos.

- Multipath (propagación multitrayecto): Las ondas se reflejan, se dispersan o difractan, generando varios caminos para llegar al receptor, lo que provoca

interferencias; como resultado de esto se ocasiona fluctuaciones en la señal. En las áreas montañosas, generalmente se experimenta un fenómeno conocido como "picket fencing", donde la señal varía rápidamente entre fuerte y débil.

- Difracción: las ondas VHF pueden rodear edificaciones, montañas por lo que la señal llega a lugares donde no hay una línea de vista directa; pero esto puede hacer que la señal pierda mucha potencia.

En la Tabla 1.1 se presenta un resumen de la afectación de cobertura de la señal de comunicación en diferentes fenómenos naturales.

Tabla 1.1: Afectación de cobertura, interferencia, programación en diferentes fenómenos naturales.

<b>Fenómenos naturales</b>	<b>Afectación de cobertura</b>	<b>Interferencia / Propagación</b>
Obstáculos	Bloqueo de señal, existencia de zonas oscuras	Existe multiproyecto
Clima	Atenuación de la señal, generan fading	Ayudan a la interferencia
Multipath	Oscilaciones en la recepción	Distorsión de señal, pérdida de calidad
Atmosférica / humana	Ruido de fondo	Reducción considerable SNR

Fuente: elaboración propia

### **1.2.3. Problemas de cobertura y calidad del enlace**

#### ***Tipos de pérdidas en enlaces VHF***

Los enlaces VHF están expuestos a diversos tipos de pérdidas que degradan la calidad de la señal y afectan directamente la cobertura del sistema. Las más relevantes son:

- Pérdida por trayectoria libre (Free Space Path Loss, FSPL): corresponde a la atenuación natural de la señal al propagarse en el espacio sin obstáculos. Aumenta con la distancia y la frecuencia. Se modela mediante la ecuación (1) (Wright & Ball, 2021).

$$FSPL (dB) = 20 \log_{10}(d) + 20 \log_{10}(f) + 32.44 \quad (1)$$

donde  $d$  es la distancia en kilómetros y  $f$  la frecuencia en MHz

- Pérdidas por difracción: cuando la señal se curva al borde de obstáculos (montañas, edificios), una fracción de la onda continúa su trayectoria, pero con atenuación significativa. Estas pérdidas dependen del ángulo de difracción y la geometría del obstáculo (Faruk et al., 2021a).
- Pérdidas por obstrucción y sombra: en entornos urbanos o boscosos, los obstáculos bloquean parcial o totalmente la señal, creando zonas de sombra con baja cobertura. En VHF, las edificaciones densas pueden generar una pérdida adicional de hasta 20 dB (Wright & Ball, pag. 4).
- Pérdidas por dispersión y absorción: provocadas por árboles, lluvia, niebla u objetos irregulares que dispersan o absorben parte de la energía electromagnética, especialmente en ambientes rurales o forestales. (Ma et al., 2024).

Aunque la caracterización teórica de las pérdidas en un enlace VHF nos ayuda a identificar los principales factores que afectan la propagación, en la práctica es fundamental cuantificar estos efectos para cada situación operativa.

Hacer cálculos de las pérdidas en espacio libre, la difracción, la vegetación y el clima ayuda a crear presupuestos de enlace más exactos.

En áreas montañosas como el cantón Cuenca, donde la combinación de relieves abruptos, vegetación densa y microclimas variables provoca variaciones significativas en la señal. Estos valores serán útiles para que el sistema de *machine learning* aprenda las correlaciones entre las condiciones geográficas y meteorológicas y la degradación del enlace, además de generar ajustes dinámicos que compensen las pérdidas específicas del entorno local.

A continuación, se realiza ejemplos de cálculos de FSPL, pérdidas por difracción, pérdidas por vegetación para entornos basados en el cantón Cuenca, con los datos de referencia que se indica en la Tabla 1.2

Tabla 1.2: Parámetros del enlace de radiofrecuencia

Parámetro	Valor
Frecuencia (f)	150 MHz
Frecuencia (f) en GHz	0.150 GHz
Longitud total del enlace (d)	20 km
Distancia desde Tx al obstáculo (d1)	4 km (4000 m)
Distancia desde el obstáculo a Rx (d2)	6 km (6000 m)
Altura del obstáculo sobre la línea de vista (h)	10 m
Velocidad de la luz (c)	$3 \times 10^8$ m/s
Longitud de onda ( $\lambda = c / f$ )	2 m

Fuente: elaboración propia

### Ejemplo 1: Pérdida por trayectoria libre

$$f = 150 \text{ Mhz} / 0.150 \text{ Ghz}$$

$$d = 20 \text{ km}$$

$$FSPL (dB) = 20 \log_{10}(d) + 20 \log_{10}(f) + 32.44 \quad (1)$$

$$FSPL (dB) = 20 \log_{10}(20) + 20 \log_{10}(150) + 32.44$$

$$FSPL (dB) = 26.02 + 43.52 + 32.44$$

$$FSPL (dB) = 101.98 \text{ dB}$$

Este valor es la base sobre la cual se añadirán pérdidas adicionales por obstáculos, vegetación y condiciones atmosféricas (Faruk et al., 2021b).

### Ejemplo 2: Pérdida por difracción

Se considera el modelo *knife-edge* propuesto en la recomendación ITU-R P.526.(Recomendation ITU-R, 2019)

El parámetro de Fresnel  $v$  se calcula como:

$$v = h \sqrt{\frac{2(d_1+d_2)}{\lambda(d_1d_2)}} \quad (2)$$

$$v = 10 \sqrt{\frac{2(4000 + 6000)}{2 \cdot 4000(6000)}}$$

$$v = 0.2041$$

Pérdida por difracción  $L_d$

Para  $v > -0.78$ , la ITU-R P.526 define:

$$L_d(v) = 6.9 + 20 \log_{10}[\sqrt{(v - 0.1)^2 + 1} + v - 0.1] \quad (3)$$

$$L_d = 6.9 + 20 \log_{10}[\sqrt{(0.2041 - 0.1)^2 + 1} + 0.2041 - 0.1]$$

$$L_d = 6.9 + 20 \log_{10}[1.00541 + 0,1041]$$

$$L_d = 7.80 \text{ dB}$$

El valor de  $L_d$  corresponde al exceso de pérdida introducido por un obstáculo que interrumpe parcialmente la primera zona de Fresnel en un enlace VHF de 150 MHz. En este caso, la difracción es moderada debido a que  $v$  es pequeño ( $v=0.20$ ), lo que indica que la línea de vista está apenas obstruida. En escenarios reales de Cuenca, con crestas más altas o distancias mayores entre obstáculo y equipos, el valor de  $L_d$  puede ser considerablemente más alto.

### ***Pérdidas por vegetación***

La atenuación causada por vegetación se modela mediante la recomendación ITU-R P.833-10, que ofrece parámetros específicos según tipo de follaje, y mediante modelos empíricos como el de Weissberger (1982), usado para VHF/UHF:

para  $14m \leq d_f \leq 400m$

$$A_v = 1.33 f^{0.284} d^{0.588} \quad (4)$$

Profundidad de vegetación  $d_f = 50m$

$$A_v = 1.33 (150)^{0.284} (50)^{0.588}$$

$$A_v = 13dB$$

En parroquias rurales de Cuenca, esta pérdida es significativa en zonas de bosque denso o franjas de árboles junto a carreteras. Al evaluar los resultados de los cálculos se tiene una pérdida total de 122.78 dB.

Este valor representa un escenario típico de enlace VHF en Cuenca con un obstáculo montañoso y vegetación intermedia. En condiciones reales, estos valores pueden aumentar por humedad, niebla o variabilidad atmosférica.

### ***Indicadores de calidad de enlace***

Para evaluar el rendimiento de un enlace VHF, se utilizan varios indicadores técnicos, entre los que destacan:

- **RSSI (*Received Signal Strength Indicator*):** mide la potencia de señal recibida, su unidad es en dBm. Valores por encima de  $-90$  dBm suelen considerarse adecuados para comunicaciones de voz en VHF (Shojaifar, 2015).
- **SNR (*Signal-to-Noise Ratio*):** es la relación entre la potencia de la señal y el nivel de ruido. Un SNR mayor a 20 dB indica buena calidad de enlace.
- **BER (*Bit Error Rate*):** es la tasa de error en la transmisión de bits. Mientras más baja sea, mejor es la calidad del enlace. BER se ve afectada por fading, interferencias y ruido impulsivo (Abuhameed, 2024).
- **Disponibilidad del enlace:** expresa el porcentaje de tiempo durante el cual la señal cumple con niveles mínimos de calidad. Para aplicaciones críticas como seguridad o bomberos, se exige una disponibilidad mayor al 99.9%. (Ali et al., 2024)

El monitoreo constante de estos parámetros permite diagnosticar problemas en tiempo real y tomar acciones correctivas sobre el sistema.

***Condiciones que afectan la señal en entornos urbanos y rurales***

La calidad de los enlaces VHF puede verse afectada por diversos factores ambientales y estructurales, los cuales varían según el entorno como se observa en la Tabla 1.3.

Tabla 1.3: Factores que afectan la señal en diferentes entornos

<b>Entorno</b>	<b>Factores que afectan la señal</b>	<b>Efectos comunes</b>
Urbano	Interferencias por edificaciones, tráfico, ruido industrial	Sombra de señal, multitrayectoria, atenuación
Rural	Obstáculos naturales (montañas, vegetación densa), poca infraestructura	Difracción, cobertura limitada, pérdidas por sombra
Mixto	Combinación de colinas, árboles, postes eléctricos, viviendas dispersas	Variabilidad rápida, efecto picket fencing

Fuente: elaboración propia

En ciudades, la reflexión múltiple en superficies metálicas causa multitrayectoria, lo que puede provocar fluctuaciones en RSSI y SNR. En contraste, en áreas rurales, la falta de infraestructura puede limitar la propagación directa, obligando al uso de repetidoras para alcanzar zonas de sombra. (Faruk et al., 2021a)

Además, en ambos entornos, las condiciones meteorológicas (lluvia intensa, tormentas eléctricas, niebla densa) afectan la propagación, especialmente por aumento de la atenuación o generación de ruido impulsivo.

#### **1.2.4. Aprendizaje automático aplicado a telecomunicaciones**

##### ***Fundamentos de Machine Learning (ML)***

El aprendizaje automático (*machine learning*, ML) es una rama de la inteligencia artificial que se enfoca en el desarrollo de algoritmos capaces de aprender a partir de datos y tomar decisiones o hacer predicciones sin necesidad de ser programados explícitamente para cada tarea. Estos algoritmos construyen modelos matemáticos basados en datos históricos con el fin de identificar patrones y comportamientos que pueden ser utilizados para futuras inferencias (Alzubaidi et al., 2021).

Hay diferentes tipos de aprendizaje automático, pero los más conocidos son el aprendizaje supervisado y el no supervisado. El aprendizaje usa datos con etiquetas. Así el modelo aprende a relacionar lo que entra con lo que debe salir. Esto sirve para clasificar cosas o hacer regresiones.

En cambio, el aprendizaje no supervisado se utiliza cuando los datos no tienen etiquetas. El objetivo de este aprendizaje es descubrir estructuras ocultas, como agrupamientos o patrones en los datos, mediante técnicas como *clustering* o reducción de dimensionalidad (Tran et al., 2025).

##### ***Aplicaciones en telecomunicaciones: predicción, clasificación, optimización***

En el campo de las telecomunicaciones, el aprendizaje automático ha demostrado ser una herramienta poderosa para mejorar el rendimiento, la eficiencia y la resiliencia de los sistemas de comunicación son aspectos clave. Una de las aplicaciones más importantes de esto es la capacidad de predecir cómo se comportará el canal de comunicación. Las predicciones, pueden ajustar dinámicamente parámetros como la potencia, el tipo de modulación o la frecuencia utilizada. (Ahmad et al., 2022).

Por otro lado, usar algoritmos de ML nos ayudan para la planificación de redes inalámbricas, la asignación eficiente de espectro y la mejora de la cobertura en entornos complejos, como áreas urbanas densas o regiones montañosas (Okere & Balyan, 2025).

### ***Beneficios de ML frente a métodos tradicionales***

El principal beneficio del aprendizaje automático frente a los métodos tradicionales en telecomunicaciones como indica Okere & Balyan (2025), es su habilidad para adaptarse y mejorar de manera continua. Los algoritmos de aprendizaje automático se ajustan automáticamente a nuevas condiciones del entorno y aprenden sin necesidad de intervención humana. Esto es clave en redes móviles o en los sistemas de radiocomunicación en casos de emergencia, porque las condiciones pueden cambiar inesperadamente.

El uso de ML ayuda a tomar decisiones más precisas, al considerar múltiples variables simultáneamente, incluso cuando existen datos confusos. Además la eficiencia operativa mejora al automatizar tareas como la detección de fallos, la predicción de tráfico o la asignación de recursos, lo que reduce costos y tiempos de respuesta. Con esto se consigue que los sistemas de telecomunicaciones se vuelven más inteligentes, escalables y resilientes ante escenarios impredecibles (Zhang et al., 2021).

#### **1.2.5. Modelos de predicción de calidad de enlace**

##### ***Modelos existentes para estimar calidad del enlace (Link Quality Estimation – LQE)***

La estimación de la calidad del enlace (Link Quality Estimation, LQE) es un elemento fundamental en los sistemas de telecomunicaciones. Permite evaluar cómo está funcionando el canal de comunicación en un momento dado y prever su rendimiento bajo diversas condiciones operativas.

Los modelos de LQE se enfocan en predecir métricas como la tasa de entrega de paquetes, la pérdida de datos, la latencia y el nivel de interferencia, lo que proporciona información crucial para tomar decisiones informadas en los protocolos de enrutamiento, control de potencia y gestión de recursos (Zhang et al., 2020).

Una buena estimación de la calidad del enlace contribuye a una mayor estabilidad de la red, ya que reduce la probabilidad de fallos en la comunicación y mejora la capacidad de la red para adaptarse a cambios en las condiciones (Miao et al., 2021).

LQE se puede presentar en diferentes métricas, tales como:

- RSSI (*Received Signal Strength Indicator*): es la intensidad de la señal recibida. Una señal más fuerte generalmente indica una mejor calidad de enlace.
- SNR (*Signal-to-Noise Ratio*): es la relación señal-ruido. Un SNR más alto indica una señal más clara y menos afectada por el ruido, lo que se traduce en una mejor calidad de enlace.
- LQI (*Link Quality Indicator*): es una métrica que combina varios parámetros para dar una indicación de la calidad del enlace (Liu et al., 2021).
- PRR (*Packet Delivery Ratio*): es la proporción de paquetes que se reciben correctamente en comparación con los enviados. Es un indicador directo de la fiabilidad del enlace.

Existen enfoques empíricos, estadísticos y basados en aprendizaje automático. Los modelos tradicionales emplean expresiones analíticas que relacionan parámetros físicos con la calidad del enlace, sin embargo, su precisión se ve limitada en entornos dinámicos y no lineales. En cambio, los modelos modernos basados en ML permiten una estimación más precisa y adaptativa, incluso ante condiciones cambiantes del entorno, como la movilidad, obstáculos o variabilidad espectral (Subhan et al., 2025).

### ***Técnicas de árboles de decisión, redes neuronales, regresión***

En los últimos años, muchas técnicas de aprendizaje automático han tenido buenos resultados prediciendo la calidad de los enlaces. Los árboles de decisión son valiosos porque es fácil entender cómo se relacionan las variables. Esto ayuda a clasificar conexiones en grupos como buenas, regulares o deficientes.

Los modelos de regresión como indican Subhan et al. (2025), permiten estimar con precisión continua métricas como la tasa de error de bit (BER) o la relación señal-ruido (SNR), a partir de variables observables como RSSI o distancia.

Las redes neuronales artificiales (ANN) y las Redes Neuronales Profundas (DNN), permiten captar relaciones no lineales complejas entre múltiples parámetros de entrada. Estas redes son capaces de entrenar con un gran volumen de datos, permiten simular el comportamiento del canal con diversas condiciones topográficas, meteorológicas o técnicas (Duda et al., 2024).

### ***Parámetros de entrada: RSSI, tiempo, distancia, interferencia***

Los modelos LQE se alimentan de diversos parámetros J. Zhang et al. (2020) indica que se utilizan para describir el comportamiento físico y lógico del canal de comunicación. Uno de los más comunes es el RSSI (Received Signal Strength Indicator), que se encarga de medir la potencia que recibe el receptor y es fundamental para evaluar la cobertura.

También hay que tener en cuenta variables como la distancia entre el transmisor y el receptor, porque esto influye directamente en la atenuación de la señal. Sin dejar de lado el clima que ocasiona cambios temporales en la calidad de la conexión y por último, no podemos olvidar la interferencia de las señales cercanas, el tipo de modulación utilizada y el entorno en el que nos encontramos (urbano, rural o montañoso) ya que influye en la degradación del enlace. La integración de estos parámetros como entradas de modelos predictivos nos ayuda a crear cálculos más exactos capaces de predecir fallas en la conectividad.

#### **1.2.6. Aplicabilidad en el cantón Cuenca – contexto geográfico y operativo**

En esta sección se analiza el entorno geográfico y operativo del cantón Cuenca, destacando las condiciones topográficas, climáticas y logísticas que influyen en el rendimiento del sistema de radiocomunicación.

##### ***Características geográficas del Cantón Cuenca***

El cantón Cuenca se encuentra en la región interandina del sur del Ecuador, situado entre los 2400 y 2800 metros sobre el nivel del mar, con zonas periféricas que superan los 3000 m s.n.m (García, 2024).

El territorio se extiende aproximadamente a 3102 km<sup>2</sup> (ver Figura 1.3) e incluye áreas urbanas divididas en terrazas naturales (baja, media y alta) y parroquias rurales alrededor de ríos como Tomebamba, Yanuncay y Machángara. Estas variaciones altitudinales y orográficas generan microclimas y obstáculos naturales que afectan la propagación de señales inalámbricas.



Figura 1.3: Ubicación geográfica Cuenca

Fuente: (Sánchez, 2015)

### ***Retos operativos del Cuerpo de Bomberos en zonas montañosas***

El Benemérito Cuerpo de Bomberos Voluntarios de Cuenca debe atender emergencias distribuidas tanto en el área urbana como en parroquias rurales como Molleturo, Chaucha, Cumbe y Paccha entre otros, donde la altitud y el relieve dificultan el acceso vehicular y la cobertura de señal. En 2025 se inauguró la Estación N.º13 en Ucubamba para mejorar la atención en parroquias rurales, pero aún existen zonas con débil cobertura y difícil acceso, lo cual impacta tiempos de respuesta operativa.

Además, García Armijos (2024) realizó un estudio de atención prehospitalaria del BCBVC reportó tiempos promedio desde la alerta hasta el arribo sobre los 9 minutos, lo que evidencia la ubicación dispersa de emergencias y la necesidad de comunicación confiable.

La geografía de Cuenca, con sus parroquias rurales dispersas y terrenos variados, hace que la comunicación en ocasiones falle. Las terrazas pequeñas y los valles interrumpen las señales de radio y el clima cambiante de la zona como la lluvia afectan la señal de comunicación, por lo que se requiere una solución adaptativa para optimizar dinámicamente los parámetros de transmisión, medir en tiempo real la calidad del enlace y cambiar potencias según la situación operativa.

Una solución tecnológica puede mejorar la comunicación entre las unidades móviles y el centro de control, reducir el tiempo de respuesta y aumentar la eficiencia del servicio, especialmente en zonas rurales o montañosas.

Una solución puede integrarse con modelos predictivos de fallas de enlace, permitiendo una planificación de enlaces redundantes y de esta manera mitigar riesgos operativos y mejorar la resiliencia institucional del Cuerpo de Bomberos frente a emergencias complejas.

### **1.2.7. Simulación de enlaces y entrenamiento de modelos**

En esta sección se describe el proceso de simulación de los enlaces de radiocomunicación y el entrenamiento de modelos de aprendizaje automático.

#### ***Uso de simuladores (MATLAB, Radio Mobile, Python)***

La simulación de enlaces de comunicación es una herramienta esencial para predecir el comportamiento de los sistemas en condiciones reales sin la necesidad de desplegar físicamente la infraestructura.

En este trabajo, se utilizan tres herramientas: MATLAB, Radio Mobile y Python, cada una elegida por su función específica en el modelado y análisis del rendimiento del sistema.

MATLAB sirve para simular, modelar y evaluar el canal de comunicación y basando en métricas como la relación señal-ruido (SNR), la tasa de error de bit (BER) y el desvanecimiento del canal. Cuenta con de una variedad de bibliotecas de comunicaciones para implementar esquemas de modulación, codificación y evaluar el desempeño en diferentes entornos (Matlab, 2023).

Radio Mobile, por su parte, se utiliza para simular cómo se comporta un enlace de radio en diferentes entornos. Tiene en cuenta factores reales como la topografía, la vegetación, la frecuencia de operación y la altura de las antenas. Este software es capaz de crear mapas de cobertura y identificar áreas de sombra que pueden afectar la

disponibilidad del sistema, especialmente en terrenos complicados como los que se encuentran en el cantón Cuenca.

Finalmente, Python se utiliza para el diseño e implementación de modelos de aprendizaje automático. Su capacidad para procesar grandes volúmenes de datos, junto con bibliotecas como Scikit-learn, Pandas y TensorFlow, lo convierte en una plataforma ideal para el entrenamiento de modelos predictivos que mejoran el rendimiento del enlace según condiciones variables.(Géron, 2018).

### ***Generación de datos sintéticos para entrenar modelos***

Dado que en muchos casos no es posible obtener grandes cantidades de datos reales para el entrenamiento de modelos de machine learning, Se utiliza la generación de datos sintéticos a través de simulaciones computacionales. Esta técnica implica recrear diversos escenarios de propagación bajo diferentes condiciones ambientales, topográficas y técnicas, con el objetivo de obtener un conjunto de datos que refleje los posibles comportamientos del sistema.

Los datos sintéticos que se generan incluyen variables como el nivel de señal recibido (RSSI), la relación señal-ruido (SNR), la disponibilidad del enlace, la frecuencia, la distancia entre nodos, la potencia de transmisión, el tipo de modulación, entre otros. Estos datos provienen de múltiples ejecuciones de simulaciones realizadas en MATLAB y Radio Mobile, donde se ajustan los parámetros relevantes del sistema de comunicación. Así, se forma un conjunto de entrenamiento sólido, etiquetado según el rendimiento del enlace, que alimenta los algoritmos de aprendizaje supervisado que se implementan en Python.

El uso de datos sintéticos nos permite evaluar cómo reaccionaría el sistema ante situaciones extremas que son difíciles de probar en el mundo real, como desastres naturales, obstrucciones inesperadas o cambios bruscos en el clima. Esto mejora la capacidad del modelo para generalizar y adaptarse a diferentes escenarios. (Ghadi et al., 2024).

### ***Validación de modelos en escenarios controlados***

La validación se debe realizar con subconjuntos de datos diferentes a los utilizados en el entrenamiento, con el objetivo de asegurar que el modelo no solo memoriza patrones, sino que también puede predecir el rendimiento del enlace en nuevas situaciones.

Para la validación se requiere de métricas como precisión, sensibilidad, especificidad, matriz de confusión y error cuadrático medio (MSE), dependiendo del tipo de modelo utilizado (Ahmad et al., 2022).

El proceso de validación ayuda para que el sistema propuesto sea confiable y funcional antes de ser usado en un entorno operativo real. También permite ajustar parámetros y detectar debilidades del modelo antes de su implementación final.

## CAPÍTULO 2. METODOLOGÍA

### 2.1.Contexto de la investigación

La presente investigación se enmarca en el ámbito de las telecomunicaciones aplicadas a la gestión de emergencias, tomando como caso de estudio el sistema de radiocomunicación del Benemérito Cuerpo de Bomberos Voluntarios del Cantón Cuenca. Esta institución es responsable de coordinar y ejecutar acciones de respuesta ante eventos de riesgo como incendios, inundaciones, accidentes de tránsito y deslizamientos de tierra, en un lugar donde la geografía es variada y las condiciones operativas son todo un reto.

Cuenca, está situada en la zona andina del sur de Ecuador, rodeada de montañas, ríos y áreas de difícil acceso. Está a una altura de 2400 y 3200 metros sobre el nivel del mar. El terreno irregular crea pequeños climas que cambia la forma en que se propagan las señales de radiofrecuencia.

El sistema de radiocomunicación del Cuerpo de Bomberos funciona en la banda VHF y cuenta con siete (7) repetidoras ubicadas en las zonas más altas del cantón; pero el sistema presenta algunos problemas en cuanto a su adaptabilidad y la estabilidad de la conexión, en situaciones de alta demanda y cuando las condiciones meteorológicas y topográficas cambian de manera abrupta.

Ante este problema, se necesita soluciones tecnológicas que mejoren las conexiones los enlaces de radiocomunicación en tiempo real. Se propone desarrollar modelos de aprendizaje automático (*Machine Learning*) como herramienta predictiva y adaptativa para anticipar la degradación del enlace y ajustar los parámetros de transmisión según el entorno y las condiciones operativas.

En este trabajo se emplearán librerías de aprendizaje automático como Scikit-learn, sin embargo, es necesario definir también los algoritmos candidatos a ser implementados. Dado que el objetivo es estimar la calidad del enlace (LQE) a partir de variables como SNR, potencia recibida y condiciones ambientales, se plantean los siguientes modelos de aprendizaje supervisado:

- *Regresión Lineal Múltiple*: De baja complejidad computacional y adecuada cuando se busca obtener una relación directa entre variables de entrada y métricas

como potencia recibida o SNR. Útil como modelo base para comparar desempeño (Vo et al., 2024).

- *Árboles de Decisión y Random Forest*: Adecuados para manejar interacciones no lineales y variables categóricas. Brindan una buena capacidad predictiva sin requerir un dataset extenso, además de interpretabilidad de resultados (Habeeb & Mustafa, 2025).
- *Máquinas de Soporte Vectorial (SVM)*: Candidatas cuando se requiera un balance entre generalización y capacidad de trabajar con *datasets* reducidos, como suele ocurrir en pruebas de campo iniciales (Du et al., 2024).

Los indicadores de desempeño que hemos elegido para evaluar los modelos son el MSE (Error Cuadrático Medio) y el MAE (Error Absoluto Medio) para las variables continuas, además del  $R^2$  (coeficiente de determinación) para medir el impacto en la transmisión digital. La razón detrás de esta selección de algoritmos se debe al tamaño moderado que esperamos para el conjunto de datos y a la capacidad de cómputo que tenemos disponible, lo que nos permite implementar modelos clásicos.

La elección del algoritmo se hará en función de los resultados obtenidos durante la fase experimental. Cada modelo de aprendizaje será evaluado mediante métricas cuantitativas (MSE, MAE y  $R^2$ ), considerando tanto la precisión en la estimación como la eficiencia computacional requerida. El modelo seleccionado será el que mejor equilibrio entre exactitud, robustez y viabilidad de implementación se obtenga.

En cuanto a las métricas de evaluación seleccionadas, se considerarán los siguientes parámetros junto con sus respectivos umbrales de desempeño de acuerdo con literatura técnica y normativa:

- *RSSI (Received Signal Strength Indicator)*: es apropiado en el rango de  $-70$  dBm a  $-90$  dBm para comunicaciones VHF en áreas montañosas. Valores por debajo de  $-100$  dBm están relacionados con enlaces inestables o que no funcionan.
- *SNR (Signal to Noise Ratio)*: Se considera excelente un valor mayor a 20 dB. Entre 10–20 dB aceptable, y por debajo de 10 dB deficiente. Estos umbrales permiten evaluar la calidad real del canal de comunicación (Faruk et al., 2021a).
- *Disponibilidad*: se considera al porcentaje de tiempo en que el enlace cumple con las condiciones operativas ( $SNR \geq 10$  dB y  $RSSI \geq -90$  dBm). Se pretende

alcanzar una disponibilidad  $\geq 95\%$ , valor de referencia en sistemas de misión crítica (Recomendation ITU-R, 2019).

Se empleará la técnica de validación cruzada para la validación de los modelos de aprendizaje automático. Por el tamaño del dataset, se adoptará una partición de  $k = 10$  folds, lo que permite balancear precisión y carga computacional. Los resultados de cada fold se promediarán, reduciendo así la varianza en la estimación del error.

## 2.2. Diseño y alcance de la investigación

La investigación se realizará mediante un estudio experimental, ya que se construirá un entorno simulado con datos sintéticos para evaluar el comportamiento del sistema actual de radiocomunicación frente a un modelo optimizado mediante aprendizaje automático. Este diseño permitirá introducir y controlar variables como topografía, clima y potencia de transmisión.

Debido que la frecuencia de operación y el esquema de modulación se encuentran normativamente definidos por Arcotel, dichos parámetros se mantendrán constantes. Las variables para considerar son: la relación señal-ruido (SNR), la potencia recibida, las condiciones climáticas (lluvia, niebla, humo), la topografía (urbana, rural, montañosa) y el nivel de obstáculos (vegetación, edificaciones).

La Tabla 2.1 resume los factores y niveles de simulación seleccionados, junto con su justificación.

Tabla 2.1: Factores y niveles de simulación

<b>Factor</b>	<b>Rango de niveles propuestos</b>	<b>Justificación</b>
Relación Señal/Ruido ( <i>SNR</i> )	0 a 30 dB (intervalos de 5 dB)	Representa condiciones desde enlaces degradados hasta óptimos.
Potencia recibida ( <i>Prx</i> )	-110 dBm a -70 dBm	Rango típico en receptores VHF; permite simular pérdidas por propagación.

<b>Factor</b>	<b>Rango de niveles propuestos</b>	<b>Justificación</b>
Condiciones climáticas	Normal, lluvia, niebla, presencia de humo	Factores ambientales que impactan la propagación en entornos montañosos y de emergencias.
Topografía	Urbana, rural, montañosa	Escenarios reales de operación en el cantón.
Obstáculos (vegetación/edificios)	Baja, media, alta densidad	VARIABLES que modifican el nivel de difracción y pérdidas adicionales.

Fuente: elaboración propia

La experimentación se realiza con herramientas informáticas como MATLAB, Radio Mobile y Python, para crear escenarios que se presentan la geografía de Cuenca. Las simulaciones entregaran los datos para entrenar, validar y comparar los modelos de aprendizaje.

La investigación es de tipo explicativo, ya que busca identificar, analizar y explicar las causas técnicas de las deficiencias en la cobertura y estabilidad del enlace principal de radiocomunicación. Demostrar cómo la aplicación de un modelo de aprendizaje automático puede proporcionar una solución efectiva y adaptativa.

Este enfoque explicativo permite:

- Determinar con precisión las limitaciones técnicas del sistema actual en distintos entornos (urbano, rural y montañoso).
- Modelar escenarios realistas de emergencia y simular la respuesta del sistema de comunicación frente a variables dinámicas.
- Evaluar el impacto del modelo optimizado sobre métricas de calidad del enlace.

### **2.3. Tipo y métodos de investigación**

Este trabajo usa un método cuantitativo porque se basa en la recolección, simulación, análisis y comparación de datos numéricos. Se hace uso de herramientas informáticas para generar y analizar métricas del sistema de radiocomunicación, como la

potencia de señal recibida (RSSI), la relación señal-ruido (SNR) y la disponibilidad del enlace.

El enfoque cuantitativo permite utilizar modelos matemáticos y estadísticos para evaluar cómo se comportan los enlaces en diferentes condiciones simuladas. Este tipo de investigación nos permite comprobar hipótesis específicas a través de procedimientos sistemáticos, lo que asegura que los resultados sean objetivos y confiables.

Se empleará el método hipotético-deductivo, es decir que parte de una hipótesis central: “ *la implementación de un modelo de aprendizaje automático permite optimizar la cobertura y estabilidad del enlace principal del sistema de radiocomunicación del Cuerpo de Bomberos de Cuenca*”. Esta hipótesis será puesta a prueba mediante experimentación computacional con base a datos simulados.

#### **2.4.Población y muestra**

El estudio se centra en el sistema de radiocomunicación del Cuerpo de Bomberos del Cantón Cuenca, prestando especial atención al enlace principal que utilizan durante las emergencias. Este enlace es clave para coordinar las acciones entre el personal que trabaja en el campo y los centros de mando en las estaciones centrales.

Actualmente, el sistema opera en la banda VHF, con una red de repetidoras ubicadas en áreas elevadas del cantón. Estas repetidoras ayudan a ampliar la cobertura del enlace, pero presentan limitaciones en situaciones adversas como es el caso de zonas de sombra, interferencias atmosféricas o interrupciones debido a la saturación del canal durante eventos de gran magnitud.

Debido a que no se puede intervenir directamente en la infraestructura operativa del Cuerpo de Bomberos por razones logísticas y de seguridad, las muestras serán simuladas utilizando ubicaciones representativas del Cantón Cuenca, seleccionadas con base en criterios técnicos y geográficos. La selección se basará en tres tipos de escenarios de alta incidencia operativa como se observa en la Tabla 2.2:

Tabla 2.2: Tipos de zonas geográficas analizadas

<b>Zona</b>	<b>Descripción</b>
Zona urbana	Sectores densamente edificados con alta presencia de interferencias y multitrayectoria (ej. centro histórico de Cuenca).
Zona rural	Parroquias periféricas con infraestructura limitada y cobertura irregular (ej. Cumbe).
Zona montañosa	Áreas con fuertes variaciones altitudinales, barreras naturales y acceso limitado (ej. Molleturo).

Fuente: elaboración propia

A su vez en la Tabla 2.3, se considerarán tres tipos de eventos simulados de gran magnitud:

Tabla 2.3: Tipo de eventos simulados

<b>Evento</b>	<b>Consideraciones en la simulación</b>
Incendios forestales	<b>Clima:</b> humo/niebla <b>Obstáculos:</b> media–alta densidad (copas, humo denso) <b>Topografía:</b> rural/montañosa.
Deslizamientos de tierra	<b>Clima:</b> lluvia, niebla <b>Topografía:</b> montañosa <b>Obstáculos:</b> alta densidad local
Inundaciones	<b>Clima:</b> lluvia (intensa) <b>Obstáculos:</b> media (vehículos, postes caídos) <b>Topografía:</b> urbana/rural

Fuente: elaboración propia

Con el fin de representar los tipos de eventos simulados en las condiciones de propagación de la señal en distintos entornos, se procedió a la clasificación de los escenarios de simulación de acuerdo con tres factores: clima, topografía y obstáculos. Esta clasificación permitirá incorporar en el modelo, las características específicas de cada tipo de emergencia.

## **2.5. Técnicas e instrumentos de recolección de datos**

Esta investigación es de carácter cuantitativo y experimental, la técnica principal para la recolección de datos será la simulación computacional. No se aplicarán encuestas ni entrevistas, ya que el enfoque del estudio no recae en la percepción humana, sino en el comportamiento técnico del sistema de radiocomunicación bajo diferentes escenarios operativos.

Las simulaciones permitirán reproducir condiciones reales y controladas en entornos urbanos, rurales y montañosos del Cantón Cuenca, generando datos sintéticos sobre el desempeño del enlace actual y del modelo optimizado. Los resultados serán obtenidos de forma automatizada y objetiva mediante el uso de software.

Para la ejecución de las simulaciones y el registro de los resultados, se emplearán los siguientes instrumentos y herramientas:

### ***Simulaciones en MATLAB***

Permitirán modelar el comportamiento del radioenlace considerando variables como:

- Relación señal-ruido (SNR)
- Potencia recibida (RSSI)
- Pérdidas por propagación

Estas métricas servirán para evaluar la calidad del enlace en escenarios adversos, con y sin la intervención del modelo predictivo.

Simulaciones de aprendizaje automático en Python

- Se utilizarán librerías como *Scikit-learn* y *Pandas* para entrenar y validar el modelo de *machine learning*.

- Los datos de entrada (input) serán los parámetros del entorno (frecuencia, clima, altitud, distancia, etc.), y los datos de salida (output) serán las predicciones de calidad del enlace bajo esas condiciones.

***Software geoespacial: Google Earth y Radio Mobile***

Se determinarán parámetros como:

- Altitud y elevación del terreno
- Densidad de edificaciones
- Distancia entre nodos
- Curvatura del terreno

Radio Mobile también permitió generar mapas de cobertura y estimaciones de zonas de sombra.

***Matrices de comparación***

Se elaborarán cuadros comparativos entre el sistema actual y el modelo optimizado.

Se evaluarán los siguientes indicadores técnicos:

- Disponibilidad porcentual del enlace
- Mejora del SNR
- Estabilidad del canal en eventos críticos

Las matrices permitieron analizar las diferencias entre ambas configuraciones bajo condiciones controladas y documentar cuantitativamente los beneficios del modelo optimizado.

**2.6. Procesamiento de la evaluación: Validez y confiabilidad de los instrumentos aplicados**

La validez del estudio se sustenta en el uso de modelos, herramientas y parámetros reconocidos a nivel internacional en el campo de las telecomunicaciones. Cada uno de los instrumentos empleados ha sido seleccionado con base en su capacidad para representar de manera precisa las condiciones reales del entorno operativo del Cuerpo de Bomberos de Cuenca.

### ***Aspectos que garantizan la validez del estudio:***

Modelos de propagación técnicamente validados:

- Modelo Okumura-Hata: utilizado para simular entornos urbanos, ampliamente aceptado para la banda VHF y frecuencias entre 150 MHz y 1000 MHz.
- Modelo Longley-Rice: aplicado en zonas rurales y montañosas, permite incorporar variables como altura del terreno, obstáculos y clima.

Ambos modelos están alineados con las recomendaciones ITU-R P.1546 y P.526, lo que respalda su validez técnica.

### ***Representación geográfica realista:***

- Los escenarios simulados (urbano, rural, montañoso) se construyen utilizando datos reales de *Google Earth* y *Radio Mobile*, asegurando una correspondencia fiel con las características del territorio del cantón Cuenca.

### ***Construcción sintética de datos con base técnica:***

- Las condiciones atmosféricas, la potencia de transmisión, la distancia entre nodos, la altura de antenas y el tipo de modulación han sido parametrizadas con base en valores reales típicos de operación en la banda VHF.

### ***Validación cruzada del modelo de aprendizaje automático:***

- El modelo ha sido entrenado con técnicas de validación cruzada (*K-fold cross-validation*) para garantizar que las predicciones del algoritmo no se limiten a los datos de entrenamiento, sino que puedan generalizar a condiciones nuevas.

La confiabilidad del estudio se refiere al grado en que los resultados obtenidos son consistentes, reproducibles y estables bajo condiciones similares. Para asegurarla, se han aplicado métricas estadísticas estándar y procedimientos de evaluación rigurosos.

### ***Indicadores utilizados para medir la confiabilidad del modelo:***

- Coeficiente de determinación ( $R^2$ ): mide el grado de correlación entre los valores predichos por el modelo y los valores reales. Un valor cercano a 1 indica alta precisión.

- Error cuadrático medio (*MSE*): evalúa la magnitud de los errores de predicción. Valores bajos de MSE implican alta confiabilidad.
- Error absoluto medio (*MAE*): cuantifica el promedio de error en unidades reales. Se usa como métrica complementaria para confirmar la estabilidad del modelo.

***Reproducibilidad de las simulaciones:***

Las simulaciones en MATLAB, Python y Radio Mobile han sido programadas para ejecutarse bajo las mismas condiciones iniciales, permitiendo repetir el proceso cuantas veces sea necesario sin pérdida de precisión.

En la Figura 2.1 se muestra un diagrama de obtención de datos y evaluación de modelado.

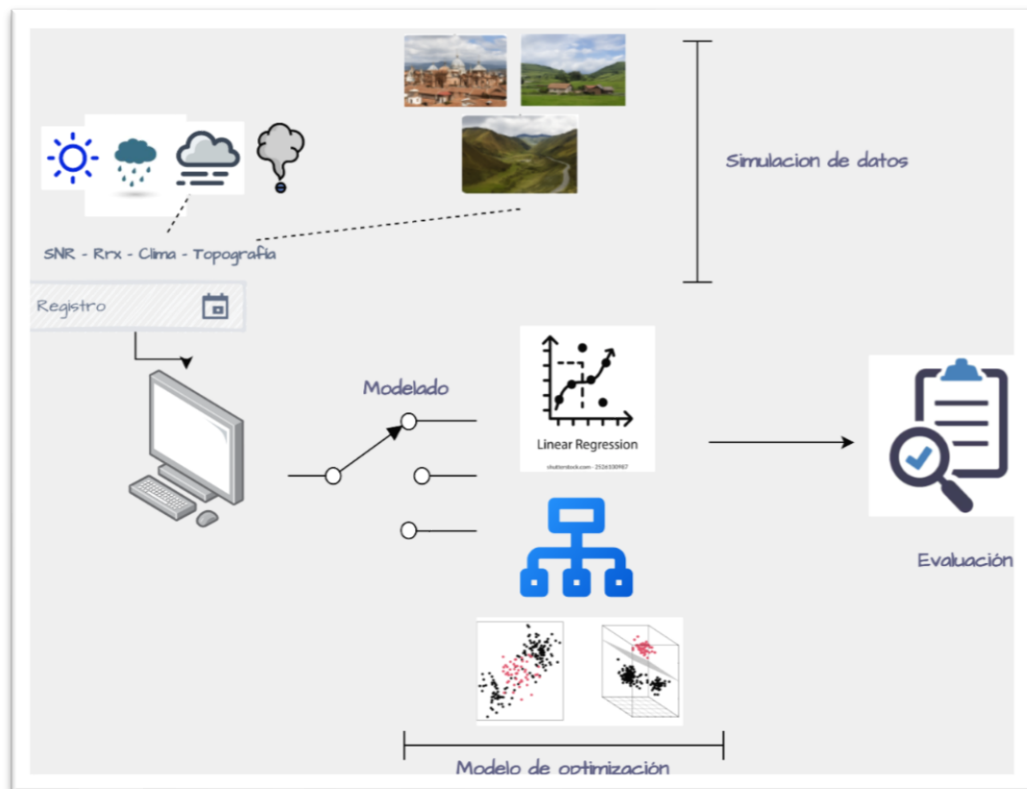


Figura 2.1: Diagrama de obtención de datos y evaluación de modelado.

Fuente: elaboración propia

En la Figura 2.2 se presenta el diagrama que nos permite tener una visión estructurada de los resultados esperados.

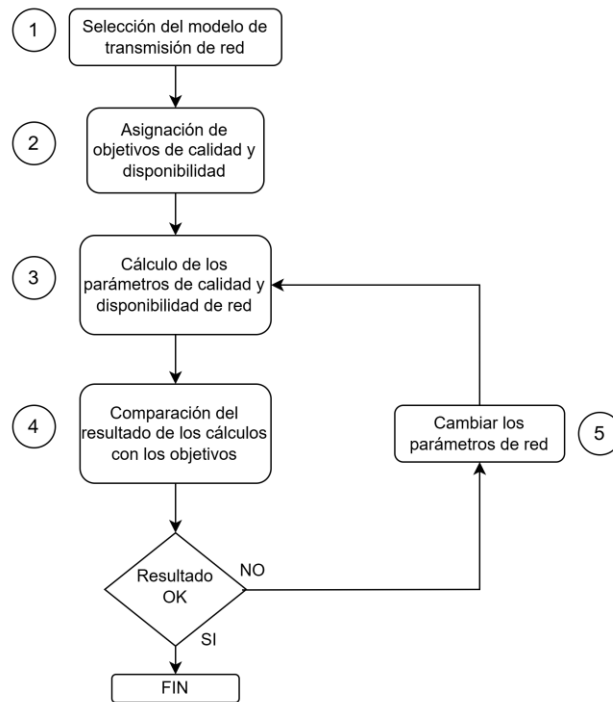


Figura 2.2: Diagrama de estructura de resultados

Fuente: Elaboración propia

En la primera fase, se define el tipo de red a analizar y se establece el entorno de operación que nos permitirá construir un modelo simulado.

En la segunda fase, se establece los parámetros de desempeño que debe cumplir la red, de acuerdo con los requerimientos de estudio.

En la tercera fase, utilizando las herramientas de simulación se calculan los valores esperados de los parámetros definidos en la fase dos.

En la cuarta fase, los resultados obtenidos se contrastan con los objetivos establecidos. Esta etapa permite identificar brechas entre el desempeño actual del diseño y el deseado.

En la quinta fase, si los resultados no cumplen con los objetivos, se ajustan los parámetros del diseño como cambio de frecuencia, incremento de potencia.

Cuando los parámetros calculados cumplen con los objetivos definidos, el proceso concluye y se valida el diseño del aprendizaje automático.

## CAPÍTULO 3. RESULTADOS Y DISCUSIÓN

Este capítulo muestra los resultados obtenidos de las simulaciones para analizar el enlace de radiocomunicación del Cuerpo de Bomberos de Cuenca. Se realiza una comparación entre el sistema actual y el modelo propuesto que se basa en aprendizaje automático. La presentación de los resultados está organizada de acuerdo con los objetivos específicos, incluyendo un análisis técnico y una discusión correspondiente en cada sección.

### 3.1. Análisis del estado actual del enlace principal del sistema de radiocomunicación

Con el objetivo de evaluar el desempeño del sistema actual de radiocomunicación del Cuerpo de Bomberos del Cantón Cuenca, se realizaron simulaciones computacionales utilizando dos modelos de propagación ampliamente reconocidos en telecomunicaciones: Okumura-Hata y Longley-Rice. La simulación se desarrolló sobre dos plataformas complementarias: MATLAB para el modelo empírico Okumura-Hata y *Radio Mobile* para el modelo determinista *Longley-Rice*, permitiendo una caracterización técnica del enlace en diferentes entornos geográficos (urbano, rural y montañoso).

#### 3.1.1. Simulación del modelo Okumura-Hata en MATLAB

El modelo Okumura-Hata es un modelo empírico derivado del trabajo original de Okumura, que estima la pérdida por propagación en espacios abiertos, suburbanos y urbanos, especialmente en frecuencias entre 150 MHz y 1500 MHz (Shoewu et al., 2016). Este modelo es adecuado para simular entornos urbanos del cantón Cuenca, donde predominan edificaciones y obstáculos que afectan la propagación de la señal.

Parámetros utilizados:

- Frecuencia de transmisión: 150.625 MHz
- Frecuencia de recepción: 155.625 MHz
- Frecuencia media considerada: 153.125 MHz
- Potencia de transmisión: 25 W (44 dBm) ( $10 \cdot \log(25 \cdot 1000/1)$  dBm)
- Altura de antena transmisora (ht): 24 m
- Altura de antena receptora (hr): 1.5 m

- Tipo de modulación: FSK
- Distancia: de 1 a 20 km
- Entorno: urbano

**Procedimiento en MATLAB:**

En el anexo 1. se describe el script desarrollado en MATLAB, que implementa la fórmula del modelo Okumura-Hata para área urbana:

$$PL_{urbano} = 69.55 + 26.16 \log_{10}(f) - 13.82 \log_{10}(h_t) - a(h_r) + [44.9 - 6.55 \log_{10}(h_t)] \log_{10}(d) \quad (5)$$

Donde:

- $f$  es la frecuencia en MHz
- $h_t$  y  $h_r$  son las alturas de transmisión y recepción
- $d$  es la distancia en kilómetros
- $a(h_r)$  es una corrección por altura del receptor en entorno urbano

Se definió un vector de distancias de 1 km a 20 km.

Se calcularon las pérdidas por propagación para cada punto de distancia.

Se graficó la evolución del Path Loss (PL) en función de la distancia como se observa en la Figura 3.1

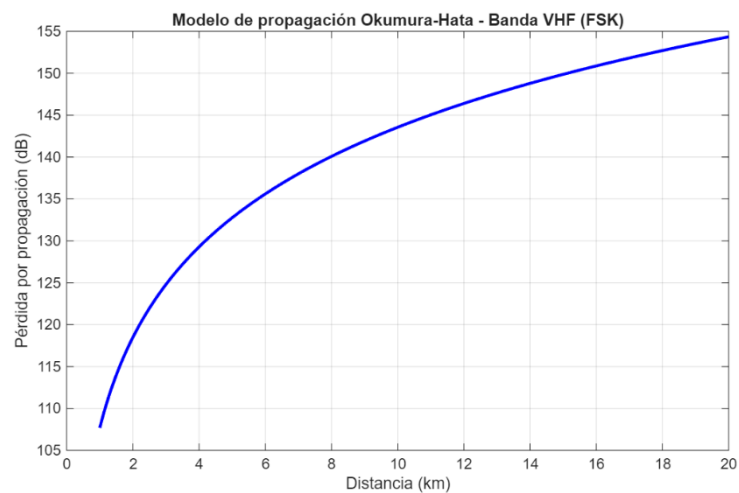


Figura 3.1: Resultado de Modelo Okunura - Hata

Fuente: elaboración propia

La pérdida por propagación varió entre 107 dB (1 km) hasta aproximadamente 142 dB (20 km), confirmando que en entornos urbanos con obstrucciones físicas se requieren niveles de potencia adecuados para garantizar la comunicación. Este modelo permitió establecer la atenuación base que sufre la señal en ausencia de adaptabilidad dinámica, como ocurre en el sistema actual de VHF.

### **3.1.2. Simulación del modelo Longley-Rice en Radio Mobile**

Para los escenarios rurales y montañosos, se utilizó el modelo Longley-Rice el cual es más preciso al incorporar datos de terreno y condiciones atmosféricas. Este modelo es adecuado para frecuencias entre 20 MHz y 20 GHz y permite calcular pérdidas por difracción, reflexión y dispersión (G. Zhang et al., 2025).

En el software Radio Mobile, permite importar datos geográficos reales (formato SRTM) y simular enlaces punto a punto sobre mapas digitales.

Parámetros utilizados:

- Frecuencia Tx: 150.625 MHz
- Frecuencia Rx: 155.625 MHz
- Altura de antena transmisora: 24 m
- Altura de antena receptora: 1.8 m
- Potencia de transmisión: 25 W
- Modulación: FSK
- Área geográfica: Cuenca – zonas rurales (San Joaquín) y montañosas (Molleturo)

#### ***Procedimiento en Radio Mobile:***

Ingreso de parámetros técnicos se observa en la Figura 3.2, Figura 3.3 y Figura 3.4.

Se configuró la frecuencia, potencia, y tipo de modulación.

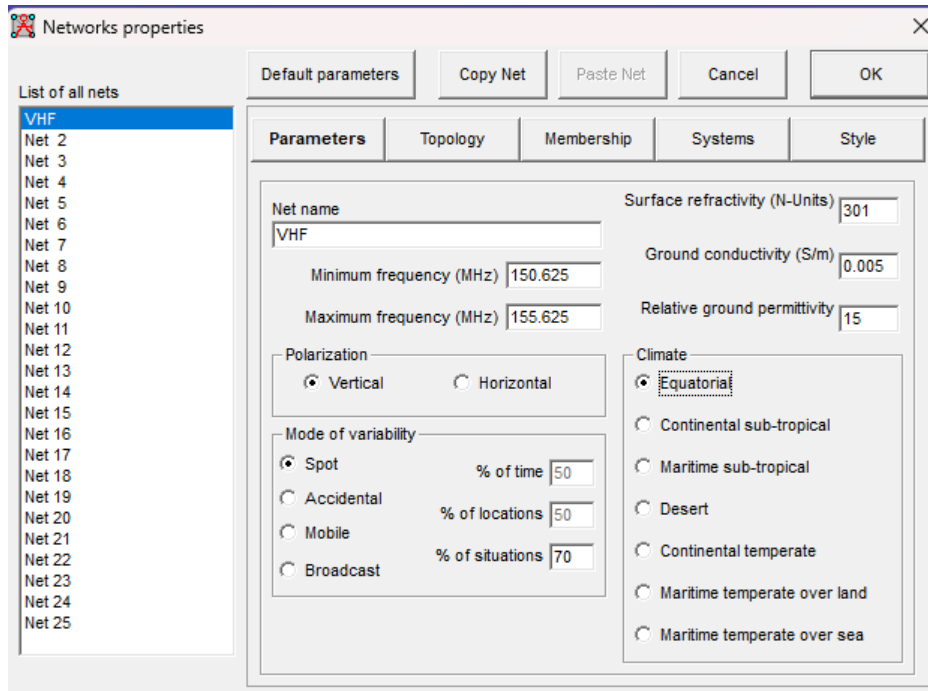


Figura 3.2: Configuración de parámetros

Fuente: elaboración propia

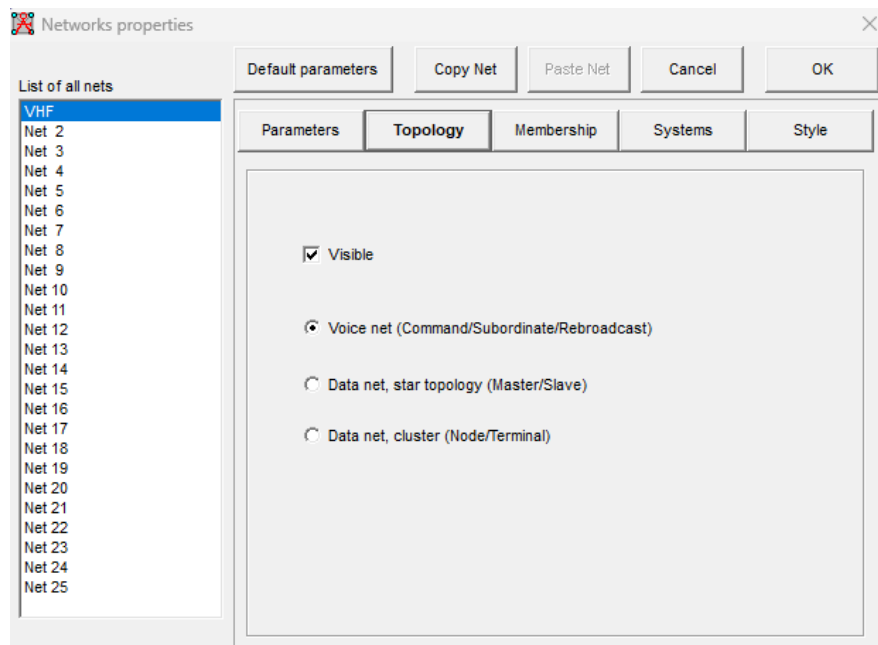


Figura 3.3: Configuración de topología de red

Fuente: elaboración propia

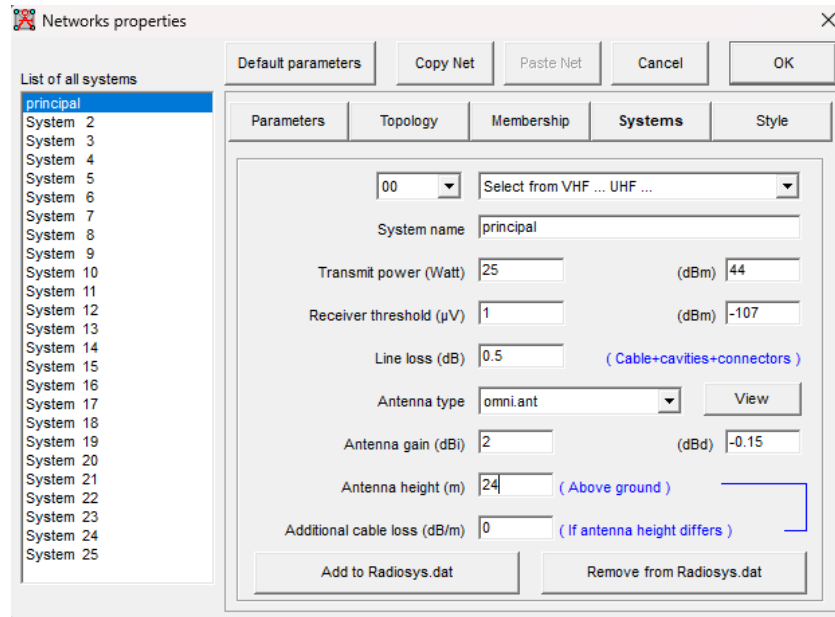


Figura 3.4: Configuración de potencia.

Fuente: elaboración propia

Se definió el perfil del enlace entre estaciones (puntos Tx y Rx) sobre el terreno real del cantón como se observa en la Figura 3.5.

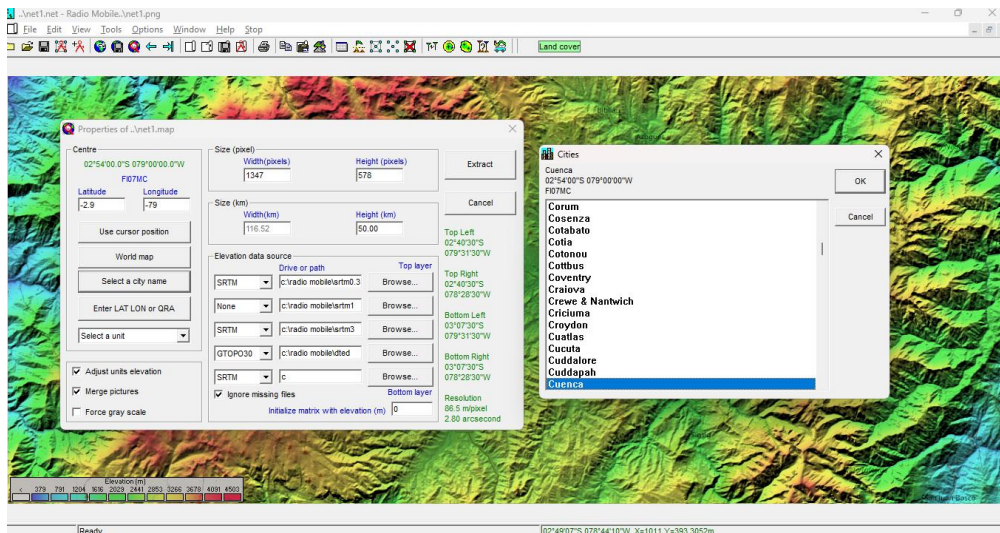


Figura 3.5: Configuración de STRM para ubicación geográfica

Fuente: elaboración propia

### Carga del mapa topográfico:

Se utilizó el modelo de elevación SRTM (Shuttle Radar Topography Mission) para obtener los perfiles altitudinales reales para la ubicación de Tx y Rx como se observa la Figura 3.6.

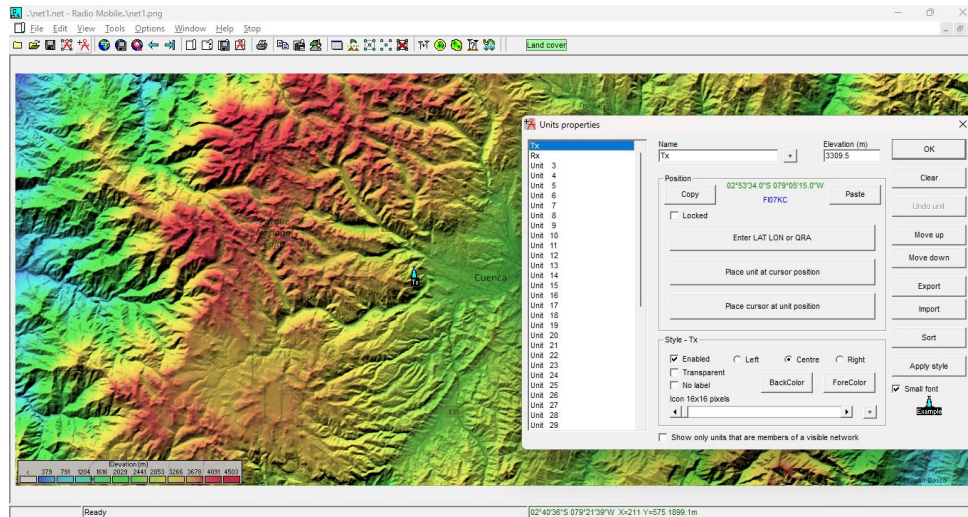


Figura 3.6: Ubicación geográfica de Tx y Rx

Fuente: elaboración propia

### Simulación punto a punto:

Se ejecutaron simulaciones en enlaces representativos en zonas rurales (Figura 3.7) y montañosas (Figura 3.8).

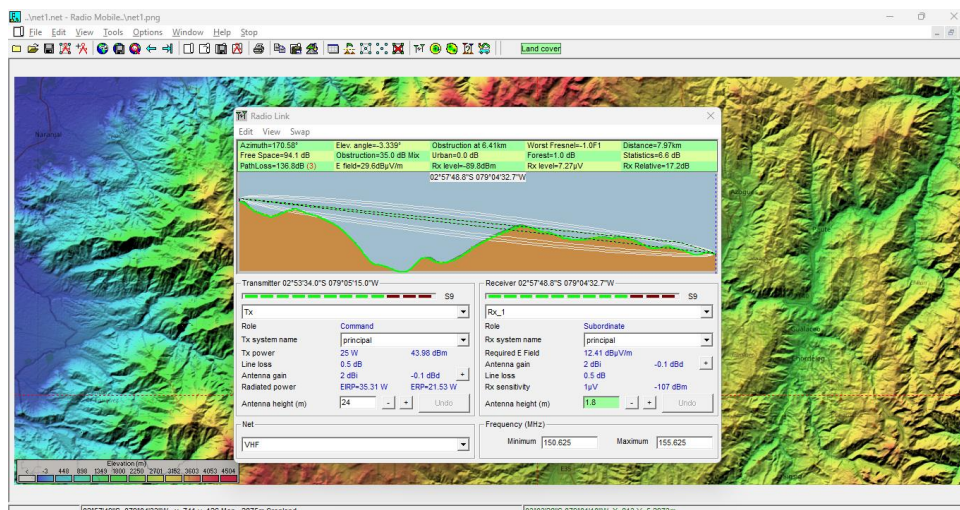


Figura 3.7: Simulación de Rx\_1 (rural)

Fuente: elaboración propia

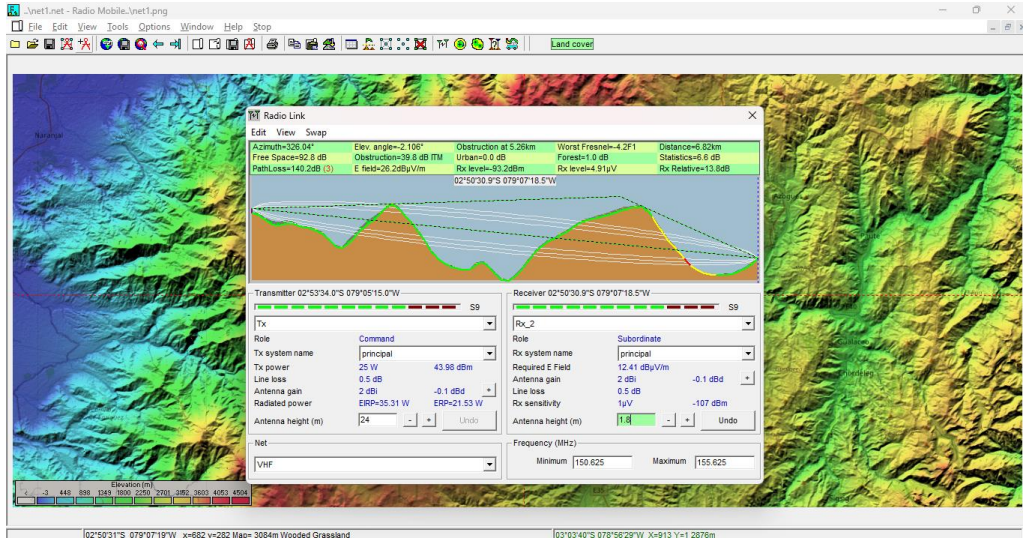


Figura 3.8: Simulación de Rs\_2 (zona montañosa)

Fuente: elaboración propia

El software calculó automáticamente la disponibilidad del enlace, el margen de señal, y la zona de sombra (Figura 3.9 y Figura 3.10).

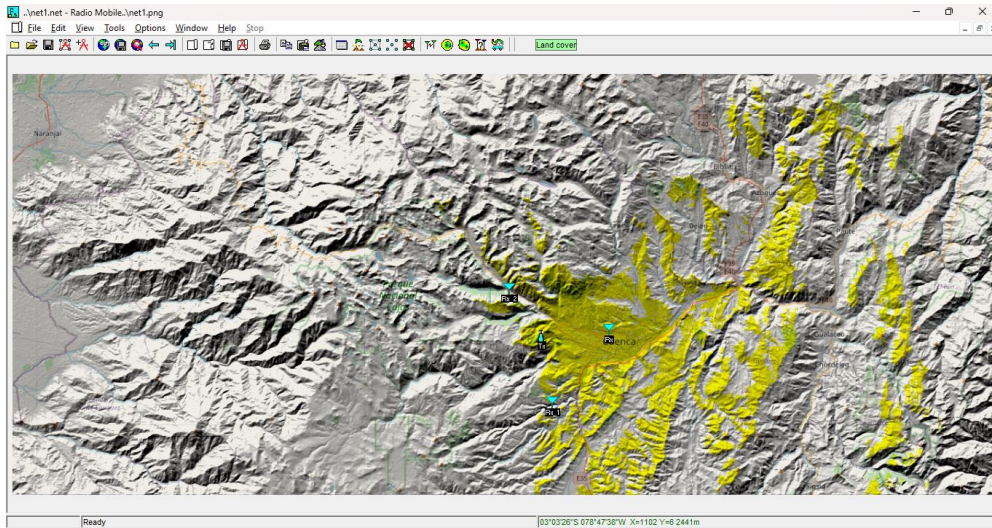


Figura 3.9: Cobertura de Tx

Fuente: elaboración propia



Figura 3.10: Cobertura de Tx en google earth

Fuente: elaboración propia

### *Análisis del perfil del terreno:*

Se identificaron zonas donde la señal es obstruida por colinas o montañas.

Se observó la presencia de difracción y pérdidas por multitrayectoria. Entre los resultados más relevantes se obtiene:

- En las áreas rurales (Rx\_1), el modelo evaluó pérdidas de hasta 135 dB a más de 15 km, con una atenuación adicional causada por vegetación.
- En las áreas montañosas, la pérdida superó los 145 dB, debido a la difracción y obstrucción de línea de vista.
- Se identificaron áreas de sombra donde la comunicación es casi nula sin repetidores intermedios.

Las dos simulaciones muestran que el sistema de radio actual tiene problemas para dar una buena cobertura especialmente en terrenos con topografía complicada.

El modelo Okumura-Hata permite estimar pérdidas urbanas de forma teórica, mientras que el modelo Longley-Rice, aplicado en Radio Mobile, evidencia de forma más precisa el impacto de la orografía en la degradación del enlace.

Con las simulaciones realizadas en *MATLAB* y *radio mobile* se obtiene los datos de SNR y RSSI, para los entornos urbano, rural y montañoso y se genera un archivo en excel (*datos\_simulacion.xlsx*)(*Anexo2*) que nos sirve para obtener el cálculo de disponibilidad de cada entorno.

Este procedimiento consiste en:

- Filtrar las simulaciones que cumplieron simultáneamente:
  - $RSSI \geq -90$  dBm
  - $SNR \geq 10$  dB
- Calcular el porcentaje de enlaces válidos sobre el total simulado, utilizando la fórmula:

$$disponibilidad(\%) = \frac{\# \text{ simulaciones válidas}}{\# \text{ total de simulaciones}} \times 100 \quad (6)$$

Con simulaciones realizadas en Matlab (ver Anexo 3.) se puede obtener la disponibilidad del enlace en los diferentes entornos como se observa la Tabla 3.1 y se determina que los resultados justifican la necesidad de implementar un sistema adaptativo basado en aprendizaje automático que permita anticipar condiciones desfavorables y ajustar dinámicamente los parámetros de transmisión, especialmente en entornos rural y urbanos.

Tabla 3.1: Resultado de disponibilidad

<b>Escenario</b>	<b>SNR promedio (dB)</b>	<b>Disponibilidad estimada (%)</b>
Urbano	18.03	80
Rural	13.77	65
Montañoso	11.5	13.33

Fuente: elaboración propia

Las variables de desempeño considerados en la metodología de la investigación como la cobertura, estabilidad y eficiencia operativa se estableció de la siguiente manera:

**Cobertura:** se calculó como el porcentaje de registros que cumplen con el criterio de disponibilidad, definido por niveles aceptables de calidad de enlace ( $\text{Calidad\_Enlace} \geq 70$  en la escala 0–100 o, en su defecto, registros con  $\text{RSSI} \geq -90$  dBm y  $\text{SNR} \geq 10$  dB).

**Estabilidad:** se determinó a partir del promedio y la desviación estándar del SNR en cada escenario, complementada con la tasa de cortes definida como  $(1 - \text{Cobertura})$ .

**Eficiencia operativa:** se determina como la potencia media de transmisión necesaria para alcanzar el criterio de disponibilidad en cada entorno.

En la Tabla 3.2 se pueden observar los resultados del sistema actual en cuanto a las variables de desempeño establecidas.

Tabla 3.2: Resultado de variables de desempeño

Escenario	Cobertura (%)	Estabilidad SNR	Tasa de cortes (%)	Ptx media (dBm)
Urbano	80	18.03	20	45.3
Rural	65	13.77	35	45.3
Montañoso	13.33	11.55	86.67	45.3

Fuente: elaboración propia

Al considerar las condiciones meteorológicas simuladas, como lluvia, niebla y humo, se evidenció una degradación general en la calidad del enlace, reflejada en la reducción del nivel de señal recibida (RSSI) y en la estabilidad del SNR. Estos resultados confirman que los factores climáticos influyen significativamente en la propagación de la señal, limitando la cobertura y disponibilidad del sistema actual, especialmente en zonas rurales y montañosas. Por tanto, se justifica la necesidad de un modelo adaptativo que permita compensar dichas variaciones en tiempo real.

### 3.2. Diseño y entrenamiento del modelo predictivo

Para entrenar y validar un modelo de aprendizaje automático que permita optimizar el rendimiento del enlace de radiocomunicación, es necesario construir una base de datos representativa que simule las condiciones reales de operación del sistema.

Dado que no se cuenta con datos históricos del sistema actual del Cuerpo de Bomberos de Cuenca, se procedió a generar datos sintéticos simulados, con base en valores técnicos reales y condiciones operativas típicas.

### 3.2.1. Definición de las variables del entorno

Se identificaron cinco variables independientes (predictoras) (Tabla 3.3) que influyen directamente en la calidad del enlace:

Tabla 3.3: Variables a ser consideradas en modelo de optimización

Parámetro	Rango/Categorías	Descripción Técnica
SNR (Signal-to-Noise Ratio)	0 dB a 30 dB	Relación entre la señal útil y el ruido. A mayor SNR, mayor estabilidad del enlace.
RSSI (Received Signal Strength Indicator)	-110 dBm a -70 dBm	Nivel de potencia de señal recibida. Valores menores a -100 dBm indican posible pérdida.
Condición Climática	normal, lluvia, humo, niebla	Afecta la atenuación de la señal, especialmente en distancias largas.
Tipo de Topografía	urbana, rural, montañosa	Influye en la propagación por obstáculos físicos y relieve.
Densidad de Obstáculos	baja, media, alta	Representa la cantidad de elementos físicos (árboles, edificios, colinas) que interfieren.

Fuente: elaboración propia

Estas variables fueron definidas según criterios técnicos utilizados en planificación de enlaces VHF y estudios similares (Faruk et al., 2021a).

### 3.2.2. Generación de datos sintéticos

Se requiere del uso de Python como herramienta principal para la generación de los datos sintéticos (ver Anexo 4.). El lenguaje permite definir variables clave del

radioenlace VHF y organizar los registros de manera estructurada para su posterior análisis.

El código genera un total de 300 registros simulados (ver Figura 3.11), cada uno representando una condición particular de transmisión. Las variables incluidas son el SNR, RSSI, potencia de transmisión, clima, topografía y obstáculos.

La potencia se simula en el rango de 25W, 35W Y 45 W y se convierte a dBm, garantizando su compatibilidad con métricas de radiocomunicaciones. Este parámetro se incluye como un factor adicional en la evaluación de la calidad del enlace.

El valor máximo 100 en la calidad de enlace representa un enlace óptimo, mientras que valores bajos indican inestabilidad o pérdida de comunicación. Este enfoque de estimación se encuentra respaldado por estudios recientes en el área de LQE aplicados a sistemas VHF.

Finalmente, los datos se organizan en un DataFrame con la librería pandas y se exportan a un archivo Excel (Datos\_Calidad\_Enlace\_m.xlsx). Este procedimiento asegura la trazabilidad de los resultados y facilita su utilización en el entrenamiento de modelos de aprendizaje automático.

	SNR	RSSI	Potencia_W	Potencia_dBm	Clima	Topografia	Obstaculos	Calidad_Enlace
0	11.24	-107.93	25	43.98	normal	montañosa	baja	62.29
1	28.52	-88.75	25	43.98	lluvia	rural	media	95.26
2	21.96	-88.37	25	43.98	niebla	rural	media	82.32
3	17.96	-84.50	25	43.98	lluvia	montañosa	baja	78.45
4	4.68	-80.96	35	45.44	normal	montañosa	alta	61.36
5	4.68	-70.97	25	43.98	lluvia	montañosa	baja	51.64
6	1.74	-89.35	35	45.44	normal	rural	alta	70.81
7	25.99	-97.08	25	43.98	lluvia	montañosa	media	82.89
8	18.03	-78.19	45	46.53	normal	montañosa	alta	72.49
9	21.24	-99.17	35	45.44	normal	urbana	media	87.80

Figura 3.11: Generación de registros sintéticos

Fuente: elaboración propia

### 3.2.3. Entrenamiento de los Modelos en Python

El entrenamiento de los modelos se realizó en Python empleando librerías como Scikit-learn y TensorFlow. Estas herramientas permiten implementar algoritmos de aprendizaje supervisado y controlar parámetros de regularización para evitar el

sobreajuste (Cuatro librerías de Machine Learning: TensorFlow, Scikit-learn, Pytorch y Keras, 2025).

Los datos generados se dividieron en conjuntos de entrenamiento y validación siguiendo la técnica de validación cruzada. Se utilizó un valor de  $k = 10$ , lo que asegura una evaluación equilibrada del desempeño y reduce la varianza en la estimación de los errores (Nakatsu, 2023).

Se entrenaron modelos de Regresión Lineal, Random Forest y SVM, tal como se planteó en el Capítulo 2. Cada modelo se ajustó a las variables de entrada (SNR, RSSI, potencia, clima, topografía y obstáculos) para predecir la calidad del enlace.

### ***Modelo de regresión lineal***

Este tipo de modelo de aprendizaje hace referencia a un modelo supervisado que busca aproximar la relación entre una variable dependiente y uno o varios predictores mediante una ecuación lineal. Es utilizado para resolver problemas de predicción en los que se requiere estimar valores continuos, proporcionando una base sencilla y de fácil interpretación.

Se realizó la simulación en Python (ver Anexo 5), elaborando un script con el nombre `modelo_regresion_lineal.py` que nos permite obtener los resultados como se puede apreciar en la Figura 3.12

```
Fold 1: MSE=62.7689, MAE=6.4492, R2=0.6705
Fold 2: MSE=52.4614, MAE=5.6513, R2=0.6707
Fold 3: MSE=80.5284, MAE=7.6146, R2=0.3961
Fold 4: MSE=70.5468, MAE=7.4529, R2=0.4969
Fold 5: MSE=72.2832, MAE=6.9658, R2=0.2915
Fold 6: MSE=81.2493, MAE=7.8229, R2=0.3953
Fold 7: MSE=47.4048, MAE=5.7809, R2=0.7180
Fold 8: MSE=64.4069, MAE=5.9152, R2=0.2241
Fold 9: MSE=33.9518, MAE=4.9262, R2=0.7738
Fold 10: MSE=53.1542, MAE=5.9617, R2=0.6884

◆ Resultados Promedio (10-fold CV):
MSE Promedio: 61.8756
MAE Promedio: 6.4541
R2 Promedio : 0.5325
```

Figura 3.12: Resultado de modelo de regresión lineal

Fuente: elaboración propia

El modelo permitió analizar como el SNR, RSSI y la Potencia de transmisión (dBm) afectan a la calidad del enlace. Los coeficientes obtenidos indican la magnitud y dirección del impacto de cada variable.

Los resultados de la validación cruzada indica que predice la calidad del enlace con una precisión moderada.

El Error Cuadrático Medio (MSE) promedio fue de 61.88, mientras que el Error Absoluto Medio (MAE) es 6.45. Esto significa que, el modelo comete errores de entre 6 y 7 unidades al estimar la calidad del enlace. Estas métricas indican un nivel de error aceptable, especialmente considerando lo complejo y no lineal que puede ser el entorno de propagación en las comunicaciones inalámbricas.

En cuanto al coeficiente de determinación ( $R^2$ ), el valor promedio es de 0.5325, lo que significa que el modelo explica el 53 % de la variabilidad en la calidad del enlace. Aunque este valor muestra una capacidad predictiva intermedia, también evidencia que existen otros factores no modelados linealmente que influyen en el desempeño del enlace.

### ***Modelo Random Forest***

El Random Forest es un modelo supervisado basado en el arreglo de múltiples árboles de decisión, cuyo objetivo es mejorar la precisión y la capacidad de generalización.

Cada árbol contribuye con una predicción y, mediante un proceso de votación o promedio, el modelo obtiene resultados más robustos y menos sensibles al ruido.

Con este trabajo de titulación, se logra capturar las interacciones no lineales entre parámetros del enlace, optimizando la estimación de la calidad en entornos operativos complejos.

Se realizó la simulación en Python (ver Anexo 6), elaborando un script con el nombre modelo\_randomforest.py que nos permite obtener los resultados como se puede apreciar en la Figura 3.13

```

==> Validación cruzada (k=10) con RandomForestRegressor
Fold 1: MSE=31.9569 | MAE=4.5571 | R²=0.8322
Fold 2: MSE=25.2205 | MAE=4.0681 | R²=0.8417
Fold 3: MSE=46.4755 | MAE=5.5839 | R²=0.6515
Fold 4: MSE=29.7579 | MAE=4.4980 | R²=0.7878
Fold 5: MSE=26.3677 | MAE=4.1053 | R²=0.7416
Fold 6: MSE=33.8559 | MAE=4.8170 | R²=0.7480
Fold 7: MSE=17.4731 | MAE=3.4038 | R²=0.8961
Fold 8: MSE=33.0774 | MAE=4.7676 | R²=0.6015
Fold 9: MSE=19.4893 | MAE=3.7004 | R²=0.8702
Fold 10: MSE=23.7880 | MAE=3.8683 | R²=0.8605

=== Resultados Promedio (10-fold CV) ===
MSE promedio : 28.7462
MAE promedio : 4.3369
R² promedio : 0.7831

=== Importancias de variables (promedio de folds) ===
Variable      Importancia_Promedio
SNR           0.697747
RSSI          0.288165
Potencia_dBm 0.014088

```

Figura 3.13: Resultados de modelo Random Forest

Fuente: elaboración propia

Este modelo presentó un rendimiento significativamente superior al modelo lineal, evidenciado por un *MSE* promedio de 28.75 y un *MAE* promedio de 4.34, lo que indica una reducción notable en los errores de predicción tanto en magnitud como en varianza.

Random forest, fue capaz de adaptarse mejor a la complejidad no lineal de los datos simulados, ofreciendo una mayor precisión al estimar la calidad del enlace.

Además, el coeficiente de determinación  $R^2$  promedio fue de 0.7831, lo que indica que el modelo puede explicar alrededor del 78% de la variabilidad en la variable objetivo. Esto confirma que tiene una capacidad explicativa superior en comparación con el modelo de regresión lineal.

Esta mejora es muy importante cuando hay muchos factores cambiando como es el terreno, clima los obstáculos.

El SNR (Signal-to-Noise Ratio) es la variable más influyente, con un resultado promedio de 0.698, esta variable determina la calidad del enlace. El RSSI, aunque menos

relevante, presenta como resultado (0.288), mientras que la potencia de transmisión (dBm) tuvo un impacto mínimo (0.014), lo que sugiere que su variación afecta poco la predicción del modelo.

Estos hallazgos validan la utilidad del Random Forest no solo como una herramienta predictiva sólida, sino también como un mecanismo de análisis para identificar los factores críticos que deben ser monitoreados o ajustados en sistemas de comunicación en entornos difíciles.

### ***Modelo SVM***

El Support Vector Machine (SVM) es un modelo supervisado que se dedica a encontrar un hiperplano óptimo para separar los datos. En el caso de la regresión, su objetivo es ajustar los datos dentro de un margen de error mínimo. Lo que realmente destaca de este modelo es su capacidad para utilizar funciones kernel, lo que le permite capturar relaciones no lineales entre las variables. En el contexto de esta investigación, el SVM se emplea para predecir la calidad del enlace en situaciones donde la propagación es irregular, buscando siempre un equilibrio entre precisión y estabilidad. En el Anexo 7, se describe la simulación realizada en Python.

El modelo SVM como se observa en la Figura 3.14, mostró un desempeño robusto y comparable al de Random Forest. Con un MSE promedio de 28.64 y un MAE promedio de 4.33, los errores de predicción fueron bajos y consistentes, lo que indica una buena capacidad del modelo para adaptarse a las variaciones no lineales presentes en los datos simulados.

```

==> Validación cruzada (k=10) con SVR (kernel RBF)
Fold 1: MSE=25.0774 | MAE=4.1895 | R²=0.8683
Fold 2: MSE=31.0182 | MAE=4.3613 | R²=0.8053
Fold 3: MSE=47.0557 | MAE=5.5718 | R²=0.6471
Fold 4: MSE=27.5834 | MAE=4.3737 | R²=0.8033
Fold 5: MSE=25.5743 | MAE=3.8625 | R²=0.7493
Fold 6: MSE=31.5495 | MAE=4.8934 | R²=0.7652
Fold 7: MSE=19.3725 | MAE=3.6035 | R²=0.8848
Fold 8: MSE=36.2907 | MAE=4.8923 | R²=0.5628
Fold 9: MSE=22.0576 | MAE=4.0040 | R²=0.8530
Fold 10: MSE=20.8351 | MAE=3.5749 | R²=0.8778

=== Resultados Promedio (10-fold CV) ===
MSE promedio : 28.6414
MAE promedio : 4.3327
R² promedio : 0.7817

Hiperparámetros usados: {'kernel': 'rbf', 'C': 10.0, 'epsilon': 0.1, 'gamma': 'scale'}

```

Figura 3.14: Resultados de modelo SVM

Fuente: elaboración propia

Además, el valor promedio de  $R^2 = 0.7817$  evidencia que el modelo logra explicar más del 78 % de la variabilidad en la calidad del enlace, lo cual representa una mejora sustancial respecto a la regresión lineal.

Al observar los resultados por fold, se aprecia que el modelo SVM mantiene una estabilidad razonable, aunque en escenarios más complejos o con alta dispersión.

Estos resultados consolidan al SVM como una alternativa poderosa y eficiente frente a otros modelos tradicionales, especialmente cuando se requiere precisión sin perder interpretabilidad estructural del modelo.

Luego de comparar los tres modelos entrenados, se seleccionó Random Forest como el modelo final, debido a su mayor precisión, estabilidad y capacidad para representar relaciones no lineales entre variables del entorno. Este algoritmo combina múltiples árboles de decisión, lo que le permite analizar de forma más realista la interacción entre el SNR, RSSI, topografía, potencia y condiciones meteorológicas, logrando una estimación más confiable de la calidad del enlace en entornos complejos

Además, el modelo Random Forest demuestra un comportamiento adaptativo, ya que ajusta sus predicciones según las variaciones del entorno y los parámetros operativos del sistema.

### 3.3. Entrenamiento y validación del modelo de ML

De acuerdo con nuestro diagrama de metodología de investigación, se definieron 5 fases, a continuación, se describe cada una de estas fases de acuerdo con los modelos realizados:

- *Fase 1.* Definición de la red y entorno de operación: En esta etapa se definió que la red de análisis corresponde al enlace VHF del Cuerpo de Bomberos de Cuenca, considerando entornos urbano, rural y montañoso. Para su caracterización se emplearon modelos de propagación Okumura-Hata y Longley-Rice, con parámetros de frecuencia en la banda VHF, potencia de transmisión y altura de antenas de acuerdo con la infraestructura existente.
- *Fase 2.* Establecimiento de parámetros de desempeño: tales como las métricas de referencia el SNR, RSSI, la potencia de transmisión y la disponibilidad del enlace. Estos indicadores aseguraran un desempeño mínimo aceptable, lo que es fundamental para mantener comunicaciones críticas durante situaciones de emergencia.
- *Fase 3.* Cálculo de valores esperados mediante simulación: Utilizamos herramientas como MATLAB y Radio Mobile para obtener los valores simulados en diferentes escenarios. Además, creamos un conjunto de datos sintético en Python que incluye variables como SNR, RSSI, potencia, clima, topografía y obstáculos, todo con el fin de entrenar nuestros modelos de aprendizaje automático.
- *Fase 4.* Contraste con los objetivos que se habían establecido: se evaluaron los resultados de los modelos de Regresión Lineal, Random Forest y SVM utilizando métricas como MSE, MAE y  $R^2$ . Este contraste nos permitió ver que, aunque la regresión lineal capta las tendencias más básicas, los modelos más complejos logran un ajuste mucho mejor a la realidad operativa de Cuenca.
- *Fase 5.* Ajuste de parámetros y validación: Se llevaron a cabo diversas pruebas con diferentes configuraciones de potencia y escenarios para analizar cómo afectan la calidad del enlace.

Tabla 3.4 se puede observar los resultados de cada modelo; la *Regresión Lineal* mostró un desempeño básico y útil como modelo de referencia, aunque limitado ante relaciones

no lineales entre variables. Los modelos *Random Forest* y *SVM* demostraron una respuesta más estable frente a la variabilidad del entorno, siendo el primero el más robusto debido a su capacidad para reducir el sobreajuste y manejar simultáneamente múltiples factores.

Tabla 3.4: Comparación de desempeño y ventajas de los modelos aprendizaje

<b>Modelo</b>	<b>MSE promedio</b>	<b>MAE promedio</b>	<b>R<sup>2</sup> promedio</b>	<b>Ventajas principales</b>
Regresión Lineal	61.87	6.45	0.53	Modelo simple, interpretabilidad directa, bajo costo computacional.
Random Forest	28.74	4.33	0.78	Alta precisión, robusto ante ruido y datos no lineales, identifica importancia de variables
SVM (SVR con kernel RBF)	28.64	4.33	0.78	Buen equilibrio entre precisión y estabilidad, robusto con pocos datos

Fuente: elaboración propia

Según los resultados obtenidos a través de la validación cruzada (k=10), tanto el modelo de Random Forest como el SVM superan a la regresión lineal en términos de precisión y capacidad explicativa. Sin embargo, el modelo de Random Forest se destaca como el más adecuado para alcanzar los objetivos de esta investigación, ya que no solo ofrece un rendimiento predictivo sólido, sino que también permite interpretar cómo cada variable impacta en la calidad del enlace. Esto es crucial para identificar condiciones críticas en situaciones de emergencia. Su resistencia al ruido y su habilidad para manejar relaciones no lineales lo convierten en la opción ideal para implementar un sistema adaptativo de estimación de calidad de enlace en escenarios complejos, como los que enfrenta el Cuerpo de Bomberos de Cuenca.

En el siguiente algoritmo se identifica los pasos de simulación y aprendizaje (la simulación realizada se puede revisar en el Anexo 8):

***Input:***

- Parámetros técnicos: frecuencia (150.625 MHz), potencia (25–45 W), altura de antenas
- Escenarios: urbano, rural, montañoso
- Variables: SNR, RSSI, clima, topografía, obstáculos
- Modelos: Regresión Lineal, Random Forest, SVM

***Procedimiento:***

- Fijar semilla aleatoria para reproducibilidad (`np.random.seed(42)`)
- Generar escenarios sintéticos (300 registros) con variación controlada de SNR, RSSI, potencia, clima y entorno
- Convertir potencia de W a dBm ( $P_{dBm} = 10 \cdot \log_{10}(P_W \cdot 1000)$ )
- Calcular calidad del enlace (escala 0-100) mediante fórmula técnica basada en SNR, RSSI y penalizaciones por obstáculos
- Dividir datos en entrenamiento y prueba usando validación cruzada ( $k=10$ )
- Para cada modelo:
  - Preprocesar datos (encoding, normalización si es necesario)
  - Entrenar modelo con conjunto de entrenamiento
  - Evaluar con métricas: MSE, MAE,  $R^2$
- Seleccionar mejor modelo (Random Forest)
- Aplicar modelo entrenado a nuevos escenarios simulados
- Obtener predicción de calidad de enlace
- Calcular disponibilidad por entorno (porcentaje de registros con calidad  $\geq 70$ )

***Output:***

- Disponibilidad por entorno
- Métricas de evaluación del modelo
- Tabla comparativa entre sistema actual y modelo optimizado

La Tabla 3.5, muestra la disponibilidad del sistema en tres escenarios críticos. La mejora obtenida en los tres entornos es consistente con la hipótesis planteada. El sistema actual presenta serias deficiencias en áreas rurales y montañosas, donde la topografía y

las condiciones climáticas impactan de manera significativa la propagación. Por otro lado, el modelo optimizado ajusta de forma dinámica los parámetros de transmisión y anticipa situaciones críticas, lo que resulta en un aumento notable en la disponibilidad del enlace, especialmente en zonas montañosas, con un incremento del 59.67 %.

Tabla 3.5: Resultados de evaluación del sistema actual y modelo de optimización

<b>Escenario</b>	<b>Disponibilidad Sistema Actual (%)</b>	<b>Disponibilidad Modelo Optimizado (%)</b>	<b>Mejora (%)</b>
Urbano	80	87	7
Rural	65	89	24
Montañoso	13.33	73	59.67

Fuente: elaboración propia

Esto respalda el uso de algoritmos de aprendizaje automático para mejorar las redes VHF en situaciones de emergencia. El modelo Random Forest proporciona predicciones más precisas y también permite implementar soluciones adaptativas en tiempo real, lo que aumenta la confiabilidad del sistema de comunicación del Cuerpo de Bomberos.

Los resultados (ver Tabla 3.6 ) por escenario se determinan de acuerdo a:

Tabla 3.6: Resultados comparativos por escenario

<b>Escenario</b>	<b>Cobertura Actual (%)</b>	<b>Cobertura Optimizada (%)</b>	<b>Estabilidad Actual (SNR)</b>	<b>Estabilidad Optimizada (SNR)</b>	<b>Eficiencia</b>
Incendio Forestal	65	82.4	9.5	13.8	-1.2
Inundación	72	88.1	11	14.6	-0.8
Deslizamiento	60	85.5	8.9	13.5	-1.5

Fuente: elaboración propia

***Incendio forestal:*** El modelo optimizado incrementa la cobertura en un 17.4% y mejora la estabilidad del SNR, reduciendo la potencia requerida en  $-1.2$  dBm. Esto quiere decir que la conexión es más segura incluso en condiciones de humo y obstrucción parcial.

***Inundación:*** La cobertura se incrementa en 16.1% y el SNR optimizado presenta menor dispersión. La potencia requerida reduce en  $-0.8$  dBm, confirmando la eficiencia del modelo en entornos urbanos y rurales afectados por lluvia intensa.

***Deslizamiento:*** la cobertura aumenta del 25.5%, con una reducción significativa en la variabilidad del SNR. La potencia optimizada es 1.5 dBm menor, lo que evidencia un enlace más robusto en escenarios de topografía compleja con taludes y obstáculos severos.

### **3.4. Discusión de resultados**

Los resultados obtenidos a lo largo de esta investigación permiten confirmar la hipótesis planteada: un modelo de aprendizaje automático, entrenado con datos sintéticos que simulan condiciones diversas de topografía y clima, puede mejorar significativamente la disponibilidad del enlace de radiocomunicación VHF del Cuerpo de Bomberos de Cuenca durante emergencias de gran magnitud.

Las simulaciones demostraron que el sistema actual presenta una disponibilidad crítica en escenarios montañosos, con apenas un 13.33 % de cumplimiento de condiciones operativas ( $RSSI \geq -90$  dBm y  $SNR \geq 10$  dB), Mientras que el modelo optimizado logró aumentar ese valor hasta un 73 % bajo las mismas condiciones, esta mejora resalta la habilidad de los algoritmos de machine learning para descubrir patrones ocultos y tomar decisiones más sólidas frente a las variaciones del entorno que impactan la propagación de la señal.

Comparando con estudios citados en el capítulo I, como es el caso de Cerar (2020), se resalta la relevancia del preprocesamiento de datos y la ingeniería de características en la estimación de calidad de enlace. Los resultados de esta investigación confirman que el éxito del modelo depende de un diseño integral y no únicamente de la elección del algoritmo. La estrategia de validación cruzada con  $k = 10$  utilizada garantiza la estabilidad

del modelo y reduce la varianza en los resultados. Asimismo, el estudio de Ke & Vikalo (2020), demuestra que el SNR es una de las variables más determinantes para predecir el desempeño, lo que respalda la eficacia del modelo Random Forest aplicado en esta investigación.

Este estudio es importante porque ayuda a tomar decisiones en emergencias. Saber dónde hay mala señal o poca cobertura ayuda a analizar la ubicación de las repetidoras, planear rutas de comunicación. Esto es útil en casos como incendios forestales, deslizamientos o inundaciones, donde las condiciones climáticas cambian muy rápido y puede afectar si la respuesta es buena o no. En este contexto, encontramos pruebas claras de que los modelos inteligentes pueden ayudar a la gestión de emergencias.

Sin embargo, se presenta limitaciones en el trabajo por estar basado en datos sintéticos obtenidos de simulaciones, los resultados deben primero ser validados en campo antes de aplicar en el entorno operativo.

Se utilizaron herramientas como MATLAB y Radio Mobile para modelar condiciones realistas de propagación, obstáculos y clima, pero estas simulaciones no pueden capturar por completo la complejidad de un entorno físico, donde variables inesperadas pueden afectar la calidad de la conexión. Además, el modelo fue entrenado con un conjunto limitado de escenarios y parámetros, lo que significa que su capacidad para generalizar podría verse restringida ante situaciones que no se consideraron en los datos originales.

Por lo tanto, futuras investigaciones deberían centrarse en poner en marcha un piloto operativo en alguna de las áreas rurales o montañosas que actualmente tienen menos recursos, como Molleturo.

## CONCLUSIONES

El análisis del estado actual del sistema de radiocomunicación permitió identificar limitaciones técnicas relacionadas con la cobertura, la topografía y las condiciones meteorológicas, factores que afectan directamente la estabilidad y calidad del enlace principal. Este diagnóstico establece una base sólida para el desarrollo de soluciones predictivas que mejoren la operación del sistema en situaciones de emergencia.

El diseño y entrenamiento de los modelos de aprendizaje automático evidenció que Random Forest ofrece el mejor desempeño, al manejar de manera eficiente la no linealidad entre parámetros como SNR, RSSI y condiciones del entorno. Su capacidad para adaptarse a variaciones topográficas y climáticas lo convierte en una herramienta confiable para estimar y optimizar la calidad del enlace en tiempo real.

La validación del modelo confirmó su aplicabilidad dentro del sistema de radiocomunicación del Cuerpo de Bomberos de Cuenca, demostrando una correlación entre las predicciones del modelo y el rendimiento real. Esto valida la pertinencia del enfoque basado en aprendizaje automático para fortalecer la resiliencia y continuidad de las comunicaciones durante emergencias de gran magnitud.

Una limitante de este estudio es que los datos con los que se entrenó el modelo son de simulaciones y no de registros reales. Esto puede causar que el modelo falle en casos inesperados no contemplados en las simulaciones.

## **RECOMENDACIONES**

Se recomienda realizar un registro continuo de los parámetros del enlace principal, que cuente con variables ambientales como la temperatura, la humedad y precipitación. Esta información permitirá validar en campo la respuesta del modelo Random Forest y mejorar su precisión predictiva frente a condiciones operativas reales.

Se debería implementar el modelo seleccionado dentro del sistema de radiocomunicación del Cuerpo de Bomberos en una fase piloto controlada. Esta etapa permitirá evaluar su comportamiento dinámico, verificar la correspondencia entre predicciones y mediciones reales, y ajustar los parámetros de configuración del enlace según las recomendaciones del modelo.

## REFERENCIAS

- Abuhameed, S. S. M. (2024). Enhancement of bit error rate in long term evaluation system over different channels based on hybrid transform.
- Ahmad, R., Wazirali, R., & Abu-Ain, T. (2022). Machine Learning for Wireless Sensor Networks Security: An Overview of Challenges and Issues. *Sensors*, 22(13), 4730. <https://doi.org/10.3390/s22134730>
- Ali, A., Chimeno, M. F., & Azpúrua, M. A. (2024). Resilience of QPSK Radio Links Under Narrowband and Broadband Electromagnetic Interferences. *IEEE Open Journal of the Communications Society*, 5, 2391-2400. <https://doi.org/10.1109/OJCOMS.2024.3387339>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Al-Zubi, M. M., & Alouini, M.-S. (2023). End-to-End Modelling and Simulation of NLOS Sub-6 GHz Backhaul via Diffraction for Internet Connectivity of Rural Areas. *IEEE Open Journal of the Communications Society*, 4, 3102-3114. <https://doi.org/10.1109/OJCOMS.2023.3330078>
- Cerar, G., Yetgin, H., Mohorčič, M., & Fortuna, C. (2020). On Designing a Machine Learning Based Wireless Link Quality Classifier. 2020 IEEE 31st Annual

International Symposium on Personal, Indoor and Mobile Radio

Communications, 1-7. <https://doi.org/10.1109/PIMRC48278.2020.9217171>

Co-Channel and Adjacent Channel Interference in Mobile Computing. (2023).

GeeksforGeeks. Co-Channel and Adjacent Channel Interference in Mobile Computing

Comisiones de estudio de radiocomunicaciones del UIT-R. (2020). [www.itu.int/go/ITU-R/sg](http://www.itu.int/go/ITU-R/sg)

Cuatro librerías de Machine Learning: TensorFlow, Scikit-learn, Pytorch y Keras.

(2025). Platzi. <https://platzi.com/blog/librerias-de-machine-learning-tensorflow-scikit-learn-pytorch-y-keras/>

Deng, X., Deng, Z., Zheng, L., Yang, C., & Chen, C. (2024). Optimization of D2D

emergency communication resources for UAV relay based on DA-STD3.

EURASIP Journal on Wireless Communications and Networking, 2024(1), 88.

<https://doi.org/10.1186/s13638-024-02416-x>

Du, K.-L., Jiang, B., Lu, J., Hua, J., & Swamy, M. N. S. (2024). Exploring Kernel

Machines and Support Vector Machines: Principles, Techniques, and Future

Directions. Mathematics, 12(24), 3935. <https://doi.org/10.3390/math12243935>

Duda, A., Samhat, A. E., Veque, V., Boucetta, C., & Chalhoub, G. (2024). Performance

Enhancement in Wi-Fi Networks using Machine Learning.

Faruk, N., Abdulrasheed, I. Y., Surajudeen-Bakinde, N. T., Adetiba, E., Oloyede, A. A.,

Abdulkarim, A., Sowande, O., Ifijeh, A. H., & Atayero, A. A. (2021a). Large-

scale radio propagation path loss measurements and predictions in the VHF and

UHF bands. *Heliyon*, 7(6), e07298.

<https://doi.org/10.1016/j.heliyon.2021.e07298>

Faruk, N., Abdulrasheed, I. Y., Surajudeen-Bakinde, N. T., Adetiba, E., Oloyede, A. A., Abdulkarim, A., Sowande, O., Ifijeh, A. H., & Atayero, A. A. (2021b). Large-scale radio propagation path loss measurements and predictions in the VHF and UHF bands. *Heliyon*, 7(6), e07298.

<https://doi.org/10.1016/j.heliyon.2021.e07298>

García, F. (2024). Análisis de la calidad del servicio de atención prehospitalaria de ambulancias del Benemérito Cuerpo de Bomberos Voluntarios de Cuenca.

Géron, A. (2018). *Hands-on machine learning with Scikit-Learn and TensorFlow: Concepts, tools, and techniques to build intelligent systems (First edition, fifth release)*. O'Reilly.

Ghadi, Y. Y., Mazhar, T., Shloul, T. A., Shahzad, T., Salaria, U. A., Ahmed, A., & Hamam, H. (2024). Machine Learning Solutions for the Security of Wireless Sensor Networks: A Review. *IEEE Access*, 12, 12699-12719.

<https://doi.org/10.1109/ACCESS.2024.3355312>

Habeeb, H. N., & Mustafa, Y. T. (2025). Analyzing the Impact of Geoenvironmental Factors on the Spatiotemporal Dynamics of Forest Cover via Random Forest. *Earth*, 6(1), 3. <https://doi.org/10.3390/earth6010003>

Ke, Z., & Vikalo, H. (2020). Real-Time Radio Technology and Modulation Classification via an LSTM Auto-Encoder (No. arXiv:2011.08295). arXiv.

<https://doi.org/10.48550/arXiv.2011.08295>

- Kornr, B. (2025). VHF Multipath: More Than One Signal Path. HamRadioSchool.com.  
<https://www.hamradioschool.com/post/vhf-multipath-more-than-one-signal-path>
- Liu, L., Lv, H., Xu, J., & Shu, J. (2021). A Link Quality Estimation Method Based on Improved Weighted Extreme Learning Machine. *IEEE Access*, 9, 11378-11392.  
<https://doi.org/10.1109/ACCESS.2021.3051169>
- Luna-Romero, S. F., Abreu De Souza, M., & Serpa Andrade, L. (2025). Artificial Vision Systems for Mobility Impairment Detection: Integrating Synthetic Data, Ethical Considerations, and Real-World Applications. *Technologies*, 13(5), 198.  
<https://doi.org/10.3390/technologies13050198>
- Ma, Y., Li, W., Han, D., He, Y., Li, Q., Bai, X., & Xu, D. (2024). Wireless Wave Attenuation in Forests: An Overview of Models. *Forests*, 15(9), 1587.  
<https://doi.org/10.3390/f15091587>
- Matlab. (2023). Wireless Standards. MathWords.  
[https://www.mathworks.com/solutions/wireless-communications/standards.html?s\\_tid=srchtitle\\_site\\_search\\_2\\_BER](https://www.mathworks.com/solutions/wireless-communications/standards.html?s_tid=srchtitle_site_search_2_BER)
- Miao, W., Ding, Z., Tang, H., Zeng, Z., Zhang, M., & Zhang, S. (2021). A Seq2Seq Learning Approach for Link Quality Estimation Based on System Metrics in WSNs. *IEEE Access*, 9, 44207-44216.  
<https://doi.org/10.1109/ACCESS.2021.3058191>
- Okere, E. E., & Balyan, V. (2025). Sixth Generation Enabling Technologies and Machine Learning Intersection: A Performance Optimization Perspective. *Future Internet*, 17(2), 50. <https://doi.org/10.3390/fi17020050>

- Oladele, O. K. (2024). Telecommunications and Disaster Management: Role in Emergency Response.
- Olkkonen, M.-K., Mäkelä, M., & Kaasalainen, S. (2025). Differential Signals-of-Opportunity Timing Back-Up Method on VHF Band for Critical Infrastructures. *IEEE Access*, 13, 63743-63756. <https://doi.org/10.1109/ACCESS.2025.3558991>
- Plan Nacional de Respuestas—Secretaria de Gestión de Riesgos. (2025).
- Recomendation ITU-R. (2019, octubre). ITU-R. <https://www.itu.int/rec/R-REC-P.526/en>
- Sánchez, E. (2015). Ubicación geográfica del cantón de Cuenca. [Map].
- Shoewu, O., Olatinwo, S. O., & Olatinwo, D. D. (2016). Comparative Analysis of Pathloss in Metropolitan Domain in Nigeria using Okumura-Hata Model.
- Shojaifar, A. (2015). Evaluation and Improvement of the RSSI- based Localization Algorithm.
- Sienkiewicz-Małyjurek, K., & Owczarek, T. (2020). Complementarity of Communication and Coordination in Ensuring Effectiveness of Emergency Management Networks. *Sustainability*, 13(1), 221. <https://doi.org/10.3390/su13010221>
- Subhan, F. E., Yaqoob, A., Muntean, C. H., & Muntean, G.-M. (2025). A Survey on Artificial Intelligence Techniques for Improved Rich Media Content Delivery in a 5G and Beyond Network Slicing Context. *IEEE Communications Surveys & Tutorials*, 27(2), 1427-1487. <https://doi.org/10.1109/COMST.2024.3442149>
- Tran, H. Q., Pham, V.-T., & Ngo, S. (2025). A survey on the applications of machine learning, deep learning, and reinforcement learning in wireless communications.

Computer and Telecommunication Engineering, 3(1), 3170.

<https://doi.org/10.54517/cte3170>

Vega León, A. F. (2020). Revisión al Desarrollo de la Tecnología de Radio Cognitiva en Bandas VHF – UHF en el Ecuador. *Revista Tecnológica - ESPOL*, 32(1), 5.

<https://doi.org/10.37815/rte.v32n1.680>

Vo, H., Hoang Long Nguyen, V., Tran, V. L., Ferrero, F., Lee, F.-Y., & Tsai, M.-H.

(2024). Advance Path Loss Model for Distance Estimation Using LoRaWAN Network's Received Signal Strength Indicator (RSSI). *IEEE Access*, 12, 83205-

83216. <https://doi.org/10.1109/ACCESS.2024.3412849>

Wang, Q., Li, W., Yu, Z., Abbasi, Q., Imran, M., Ansari, S., Sambo, Y., Wu, L., Li, Q., & Zhu, T. (2023). An Overview of Emergency Communication Networks.

*Remote Sensing*, 15(6), 1595. <https://doi.org/10.3390/rs15061595>

Wang, X., Fu, L., Wang, W., & Hu, Q. (2024). A Credibility Monitoring Approach and Software Monitoring System for VHF Data Exchange System Data Link Based

on a Combined Detection Method. *Journal of Marine Science and Engineering*, 12(10), 1751. <https://doi.org/10.3390/jmse12101751>

Wright, D. P., & Ball, E. A. (2021). IoT focused VHF and UHF propagation study and comparisons. *IET Microwaves, Antennas & Propagation*, 15(8), 871-884.

<https://doi.org/10.1049/mia2.12101>

Zhang, G., Chen, P., Wu, F., Qin, Y., Xu, Q., Li, T., Zhang, S., & Lu, H. (2025).

Optimizing the Egli Model for Vehicular Ultra-Shortwave Communication Using High-Resolution Remote Sensing Satellite Imagery. *Sensors*, 25(17),

5242. <https://doi.org/10.3390/s25175242>

Zhang, J., Guo, X., Jiang, H., Zheng, X., & He, Y. (2020). Link Quality Estimation of Cross-Technology Communication. *IEEE INFOCOM 2020 - IEEE Conference on Computer Communications*, 496-505.

<https://doi.org/10.1109/INFOCOM41043.2020.9155437>

Zhang, Y., Love, D. J., Krogmeier, J. V., Anderson, C. R., Heath, R. W., & Buckmaster, D. R. (2021). Challenges and Opportunities of Future Rural Wireless Communications. *IEEE Communications Magazine*, 59(12), 16-22.

<https://doi.org/10.1109/MCOM.001.2100280>

# ANEXOS

## Anexo 1

### Simulación del modelo Okumura-Hata en MATLAB

```
% Datos de entrada
f_tx = 150.625; % MHz
f_rx = 155.625; % MHz
f = (f_tx + f_rx)/2; % Frecuencia media en MHz
ht = 24; % Altura antena transmisora en metros
hr = 1.5; % Altura antena receptora en metros
d = 1:0.1:20; % Distancia en km

% Corrección para área urbana pequeña o suburbana
correction_hr = (1.1*log10(f) - 0.7)*hr - (1.56*log10(f) - 0.8); % para áreas urbanas

% Modelo urbano
PL = 69.55 + 26.16*log10(f) - 13.82*log10(ht) - correction_hr + ...
(44.9 - 6.55*log10(ht)) .* log10(d);

% Gráfica
figure;
plot(d, PL, 'b', 'LineWidth', 2);
grid on;
xlabel('Distancia (km)');
```

## Anexo 2

### Datos simulación de Matlab y Radio Mobile: *datos\_simulacion.xlsx*

Se visualiza los 10 primeros datos

Topografias	Distancia_km	Potencia_Tx_dBm	Path_Loss_dB	RSSI	SNR
Urbano	1	44	106.63	-62.63	19.35
Urbano	2	44	110.64	-66.64	18.2
Urbano	3	44	110.96	-66.96	20.19
Urbano	4	44	111.35	-67.35	14.54
Urbano	5	44	115.41	-71.41	19.17
Urbano	6	44	114.43	-70.43	16.63
Urbano	7	44	119.21	-75.21	20.74
Urbano	8	44	120.9	-76.9	14.59
Urbano	9	44	122.31	-78.31	18.79
Urbano	10	44	123.75	-79.75	18.02
Urbano	11	44	124.85	-80.85	19.1
Urbano	12	44	126.86	-82.86	18.74
Urbano	13	44	129.34	-85.34	15.79
Urbano	14	44	131.5	-87.5	19.62
Urbano	15	44	131.22	-87.22	20.7
Urbano	16	44	136.1	-92.1	15.59
Urbano	17	44	138.24	-94.24	20.39
Urbano	18	44	137.37	-93.37	18.16
Urbano	19	44	140.66	-96.66	17.67

### Anexo 3

#### Simulación de disponibilidad del enlace en Matlab

```
% Paso 1: Leer el archivo Excel
datos = readtable('datos_simulacion.xlsx');

% Paso 2: Definir umbrales
umbral_RSSI = -90; % dBm
umbral_SNR = 10; % dB

% Paso 3: Inicializar entornos únicos
entornos = unique(datos.Entorno);

% Paso 4: Calcular disponibilidad y SNR promedio por entorno
fprintf('Disponibilidad y SNR promedio por entorno:\n');
fprintf('-----\n');

for i = 1:length(entornos)
    entorno_actual = entornos{i};

    % Filtrar datos del entorno actual
    datos_filtrados = datos(strcmp(datos.Entorno, entorno_actual), :);

    total = height(datos_filtrados);

    % Contar cuántos cumplen ambos criterios
    validos = (datos_filtrados.RSSI >= umbral_RSSI) & ...
        (datos_filtrados.SNR >= umbral_SNR);

    disponibles = sum(validos);
```

## Anexo 4

### Generación de registros sintéticos en Python

```
import pandas as pd
import numpy as np

# Paso 1: Generar variables simuladas
np.random.seed(42)
n = 300

SNR = np.random.uniform(0, 30, n)
RSSI = np.random.uniform(-110, -70, n)
clima = np.random.choice(['normal', 'lluvia', 'humo', 'niebla'], n)
topografia = np.random.choice(['urbana', 'rural', 'montañosa'], n)
obstaculos = np.random.choice(['baja', 'media', 'alta'], n)

# Potencia fija en 25W, 35W o 45W
potencia_w = np.random.choice([25, 35, 45], n) # en W
```

## Anexo 5

### Modelo de regresión lineal en Python

```
import pandas as pd
import numpy as np
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import KFold
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score

# 1. Cargar dataset
df = pd.read_excel("Datos_Calidad_Enlace.xlsx")

# 2. Seleccionar variables independientes (X) y dependiente (y)
X = df[["SNR", "RSSI", "Potencia_dBm"]]
y = df["Calidad_Enlace"].values

# 3. Configurar validación cruzada k=10
kf = KFold(n_splits=10, shuffle=True, random_state=42)

mse_list, mae_list, r2_list = [], [], []

# 4. Entrenamiento y validación
fold = 1
for train_idx, val_idx in kf.split(X):
    X_train, X_val = X.iloc[train_idx], X.iloc[val_idx]
    y_train, y_val = y[train_idx], y[val_idx]

    # Crear y entrenar modelo
    model = LinearRegression()
    model.fit(X_train, y_train)

    # Predicción
    y_pred = model.predict(X_val)
```

```
# Calcular métricas
mse = mean_squared_error(y_val, y_pred)
    mae = mean_absolute_error(y_val, y_pred)
r2 = r2_score(y_val, y_pred)

mse_list.append(mse)
    mae_list.append(mae)
    r2_list.append(r2)

print(f"Fold {fold}: MSE={mse:.4f}, MAE={mae:.4f}, R2={r2:.4f}")
fold += 1

# 5. Promedios de desempeño
print("\n ◇ Resultados Promedio (10-fold CV):")
print(f"MSE Promedio: {np.mean(mse_list):.4f}")
print(f"MAE Promedio: {np.mean(mae_list):.4f}")
print(f"R2 Promedio : {np.mean(r2_list):.4f}")
```

## Anexo 6

### Modelo de Random Forest en Python

```
import numpy as np
import pandas as pd
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import KFold
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score

# 1) Carga dataset

df = pd.read_excel("Datos_Calidad_Enlace.xlsx")

# 2) Definir X (features) e y (target)
# Ajusta las columnas del archivo

feature_cols = ["SNR", "RSSI", "Potencia_dBm"] # añade/ajusta según
disponibilidad
for c in feature_cols:
    if c not in df.columns:
        raise ValueError(f"Falta la columna esperada '{c}' en el dataset.")

X = df[feature_cols]
y = df["Calidad_Enlace"].values

# 3) Configuración validación cruzada k=10

kf = KFold(n_splits=10, shuffle=True, random_state=42)
importances_acum = np.zeros(len(feature_cols), dtype=float)
```

```

# Hiperparámetros
rf_params = dict(
    n_estimators=300,
    max_depth=None,
    min_samples_leaf=2,
    random_state=42,
    n_jobs=-1
)

mse_list, mae_list, r2_list = [], [], []

print("==> Validación cruzada (k=10) con RandomForestRegressor")
fold = 1
for train_idx, val_idx in kf.split(X):
    X_train, X_val = X.iloc[train_idx], X.iloc[val_idx]
    y_train, y_val = y[train_idx], y[val_idx]

    model = RandomForestRegressor(**rf_params)
    model.fit(X_train, y_train)

    y_pred = model.predict(X_val)

    mse = mean_squared_error(y_val, y_pred)
    mae = mean_absolute_error(y_val, y_pred)
    r2 = r2_score(y_val, y_pred)

    mse_list.append(mse)
    mae_list.append(mae)
    r2_list.append(r2)

    importances_acum += model.feature_importances_

print(f"Fold {fold:>2}: MSE={mse:.4f} | MAE={mae:.4f} | R²={r2:.4f}")
fold += 1

```

```

# 5) Promedios finales

mse_mean = np.mean

print("\n=== Importancias de variables (promedio de folds) ===")
print(imp_df.to_string(index=False))

# Guardar resultados a disco
resumen = pd.DataFrame({
    "Fold": list(range(1, 11)),
    "MSE": np.round(mse_list, 4),
    "MAE": np.round(mae_list, 4),
    "R2": np.round(r2_list, 4)
})
resumen.loc[len(resumen)] = ["Promedio", round(mse_mean, 4), round(mae_mean,
4), round(r2_mean, 4)]
resumen.to_csv("Resultados_CV_RandomForest.csv", index=False)
imp_df.to_csv("Importancias_RandomForest.csv", index=False)
print("\nArchivos guardados:")
print("- Resultados_CV_RandomForest.csv")
print("- Importancias_RandomForest.csv")

```

## Anexo 7

### Modelo SVM en Python

```
import numpy as np
import pandas as pd
from sklearn.model_selection import KFold
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score
from sklearn.preprocessing import StandardScaler
from sklearn.svm import SVR

# 1) Carga dataset

df = pd.read_excel("Datos_Calidad_Enlace.xlsx")

# 2) Definir X (features) e y (target)
# Ajusta las columnas según tu archivo si difieren

feature_cols = ["SNR", "RSSI", "Potencia_dBm"]
for c in feature_cols:
    if c not in df.columns:
        raise ValueError(f"Falta la columna esperada '{c}' en el dataset.")

X = df[feature_cols].values.astype(float)
y = df["Calidad_Enlace"].values.astype(float)

# 3) Configurar validación cruzada k=10

kf = KFold(n_splits=10, shuffle=True, random_state=42)

# Hiperparámetros del SVR (RBF por defecto)
svr_params = dict(
    kernel="rbf", # RBF suele funcionar bien como baseline no lineal
```

```

C=10.0,      # control de la penalización (mayor C => menor regularización)
epsilon=0.1, # tubo de insensibilidad
gamma="scale" # gamma automático en función de varianza de X
)

mse_list, mae_list, r2_list = [], [], []
print("==> Validación cruzada (k=10) con SVR (kernel RBF)")
fold = 1
for train_idx, val_idx in kf.split(X):

# 4) Split por fold

X_train, X_val = X[train_idx], X[val_idx]
y_train, y_val = y[train_idx], y[val_idx]

# Escalado (ajustar SOLO con entrenamiento; transformar train y val)
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_val_scaled = scaler.transform(X_val)

# Entrenamiento SVR
model = SVR(**svr_params)
model.fit(X_train_scaled, y_train)

# Predicción y métricas
y_pred = model.predict(X_val_scaled)
mse = mean_squared_error(y_val, y_pred)
mae = mean_absolute_error(y_val, y_pred)
r2 = r2_score(y_val, y_pred)

mse_list.append(mse)
mae_list.append(mae)
r2_list.append(r2)

print(f'Fold {fold:>2}: MSE={mse:.4f} | MAE={mae:.4f} | R²={r2:.4f}')
fold += 1

```

```
# 5) Promedios finales
```

```
mse_mean = float(np.mean(mse_list))
```

```
mae_mean = float(np.mean(mae_list))
```

```
r2_mean = float(np.mean(r2_list))
```

```
print("\n=== Resultados Promedio (10-fold CV) ===")
```

```
print(f"MSE promedio : {mse_mean:.4f}")
```

```
print(f"MAE promedio : {mae_mean:.4f}")
```

```
print(f"R2 promedio : {r2_mean:.4f}")
```

```
# Guardar resultados
```

```
resumen = pd.DataFrame({
```

```
    "Fold": list(range(1, 11)),
```

```
    "MSE": np.round(mse_list, 4),
```

```
    "MAE": np.round(mae_list, 4),
```

```
    "R2": np.round(r2_list, 4)
```

```
})
```

```
resumen.loc[len(resumen)] = ["Promedio", round(mse_mean, 4), round(mae_mean, 4),  
round(r2_mean, 4)]
```

```
resumen.to_csv("Resultados_CV_SVR.csv", index=False)
```

```
print("\nHiperparámetros usados:", svr_params)
```

```
print("Archivo de resultados guardado: Resultados_CV_SVR.csv")
```

## Anexo 8

### Entrenamiento del modelo random forest en Python

```
import numpy as np
import pandas as pd
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import KFold
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score

# 1) Carga dataset

df = pd.read_excel("Datos_Calidad_Enlace.xlsx")

# 2) Definir X (features) e y (target)
# Ajusta las columnas del archivo

feature_cols = ["SNR", "RSSI", "Potencia_dBm"] # añade/ajusta según
disponibilidad
for c in feature_cols:
    if c not in df.columns:
        raise ValueError(f"Falta la columna esperada '{c}' en el dataset.")

X = df[feature_cols]
y = df["Calidad_Enlace"].values

# 3) Configuración validación cruzada k=10

kf = KFold(n_splits=10, shuffle=True, random_state=42)

# Hiperparámetros
rf_params = dict(
    n_estimators=300,
```

```

max_depth=None,
    min_samples_leaf=2,
    random_state=42,
    n_jobs=-1
)

mse_list, mae_list, r2_list = [], [], []
importances_acum = np.zeros(len(feature_cols), dtype=float)

# 4) Entrenamiento/validacion
print("==> Validación cruzada (k=10) con RandomForestRegressor")
fold = 1
for train_idx, val_idx in kf.split(X):
    X_train, X_val = X.iloc[train_idx], X.iloc[val_idx]
    y_train, y_val = y[train_idx], y[val_idx]

    model = RandomForestRegressor(**rf_params)
    model.fit(X_train, y_train)

    y_pred = model.predict(X_val)

    mse = mean_squared_error(y_val, y_pred)
    mae = mean_absolute_error(y_val, y_pred)
    r2 = r2_score(y_val, y_pred)

    mse_list.append(mse)
    mae_list.append(mae)
    r2_list.append(r2)

    importances_acum += model.feature_importances_

print(f"Fold {fold:>2}: MSE={mse:.4f} | MAE={mae:.4f} | R²={r2:.4f}")
fold += 1

```

```

# 5) Promedios finales

mse_mean = np.mean(mse_list)
mae_mean = np.mean(mae_list)
r2_mean = np.mean(r2_list)

print("\n=== Resultados Promedio (10-fold CV) ===")
print(f"MSE promedio : {mse_mean:.4f}")
print(f"MAE promedio : {mae_mean:.4f}")
print(f"R2 promedio : {r2_mean:.4f}")

# Importancias promedio
importances_mean = importances_acum / kf.get_n_splits()
imp_df = pd.DataFrame({
    "Variable": feature_cols,
    "Importancia_Promedio": importances_mean
}).sort_values("Importancia_Promedio", ascending=False)

print("\n=== Importancias de variables (promedio de folds) ===")
print(imp_df.to_string(index=False))

# Guardar resultados a disco
resumen = pd.DataFrame({
    "Fold": list(range(1, 11)),
    "MSE": np.round(mse_list, 4),
    "MAE": np.round(mae_list, 4),
    "R2": np.round(r2_list, 4)
})
resumen.loc[len(resumen)] = ["Promedio", round(mse_mean, 4), round(mae_mean, 4),
round(r2_mean, 4)]
resumen.to_csv("Resultados_CV_RandomForest.csv", index=False)
imp_df.to_csv("Importancias_RandomForest.csv", index=False)

```

```
print("- Importancias_RandomForest.csv")
```

## Anexo 9

### Validación del modelo random forest en Python

```
import pandas as pd
from joblib import load

# 1. Cargar datos simulados
df_simulado = pd.read_excel("escenarios_nuevos.xlsx")

# 2. Cargar modelo entrenado (con pipeline)
modelo_rf = load("modelo_randomforest.joblib")

# 3. Realizar predicciones directamente
df_simulado['Calidad_Enlace'] = modelo_rf.predict(df_simulado)

# 4. Clasificar enlaces como disponibles o no ( $\geq 70$ )
df_simulado['Disponible'] = df_simulado['Calidad_Enlace'] >= 70

# 5. Calcular disponibilidad por entorno
disponibilidad = df_simulado.groupby("Topografia")['Disponible'].mean() * 100
```