

# CIBERSEGURIDAD: APLICACIÓN DE TÉCNICAS DE MACHINE LEARNING PARA LA DETECCIÓN DE INTRUSIONES EN RED

---

**Trabajo Final de Máster**  
Máster en Inteligencia Artificial

**Antonio Daniel Moreno Prieto**

Tutor: 

Madrid · 26 de Mayo de 2026

# Contexto del proyecto

- La ciberseguridad es un ámbito clave en sistemas conectados
- Las redes generan grandes volúmenes de tráfico
- Es necesario detectar comportamientos anómalos o potencialmente peligrosos
- Machine Learning permite automatizar parte de esta detección



## Caso planteado



- Diferenciar conexiones normales y conexiones anómalas dentro del tráfico de red
- Analizar variables relacionadas con protocolos, servicios y comportamiento de las conexiones
- Entrenar modelos capaces de detectar patrones asociados a posibles intrusiones
- Comparar distintos modelos de Machine Learning para identificar el más eficaz

# Objetivos del proyecto




- Aplicar técnicas de Machine Learning para la detección de intrusiones en red
- Analizar un dataset de tráfico de red orientado a ciberseguridad
- Preparar y transformar los datos para el entrenamiento de modelos
- Entrenar distintos modelos supervisados de clasificación
- Evaluar y comparar el rendimiento de los modelos obtenidos

# Dataset utilizado

- Dataset público obtenido desde Kaggle
- Archivos utilizados:
  - Train\_data.csv
  - Test\_data.csv
- Cada registro representa una conexión de red
- El tráfico se clasifica como normal o anómalo

| Nº | Variable       | Descripción                        |
|----|----------------|------------------------------------|
| 1  | duration       | Duración de la conexión            |
| 2  | protocol_type  | Tipo de protocolo de red           |
| 3  | service        | Servicio de red utilizado          |
| 4  | flag           | Estado de la conexión              |
| 5  | src_bytes      | Bytes enviados desde el origen     |
| 6  | dst_bytes      | Bytes enviados desde el destino    |
| 7  | land           | Conexión entre mismo host y puerto |
| 8  | wrong_fragment | Número de fragmentos incorrectos   |
| 9  | urgent         | Número de paquetes urgentes        |
| 10 | hot            | Número de accesos sospechosos      |


## Flujo metodológico



Flujo general seguido durante el desarrollo del proyecto


# Análisis exploratorio de datos (EDA)

- Se analizaron variables numéricas y categóricas del dataset
- Se estudió la distribución de protocolos y servicios de red
- Se identificaron patrones relacionados con tráfico normal y anómalo



# Distribución de conexiones

- El dataset contiene conexiones normales y conexiones anómalas
- Esto permite plantear el problema como una tarea de clasificación supervisada
- El modelo aprende patrones para diferenciar ambos tipos de tráfico



# Preprocesado de datos


- Separación entre variables predictoras y variable objetivo
- Codificación de variables categóricas
- División en conjuntos de entrenamiento y validación
- Preparación de los datos para el entrenamiento de modelos

| <b>service_pop_3</b> | <b>service_printer</b> | <b>service_private</b> | <b>service_red_i</b> | <b>service_remote_job</b> |
|----------------------|------------------------|------------------------|----------------------|---------------------------|
| False                | False                  | False                  | False                | False                     |
| False                | False                  | False                  | False                | False                     |
| False                | False                  | True                   | False                | False                     |
| False                | False                  | False                  | False                | False                     |
| False                | False                  | False                  | False                | False                     |

# Modelos aplicados


## Regresión Logística

Modelo base de clasificación




## Árbol de Decisión

Modelo basado en reglas



## Random Forest

Conjunto de múltiples árboles




# Comparativa de resultados

- Los tres modelos obtuvieron resultados elevados
- Se compararon métricas como accuracy, precision, recall y F1-score
- Random Forest alcanzó el mejor rendimiento general

|   | Modelo              | Accuracy | Precision | Recall   | F1-score |
|---|---------------------|----------|-----------|----------|----------|
| 0 | Regresión Logística | 0.947609 | 0.937065  | 0.965322 | 0.950984 |
| 1 | Árbol de Decisión   | 0.996626 | 0.996235  | 0.997361 | 0.996798 |
| 2 | Random Forest       | 0.998015 | 0.996618  | 0.999623 | 0.998118 |


# Evaluación del modelo Random Forest

- La matriz de confusión muestra muy pocos errores de clasificación
- El modelo identifica correctamente la mayoría de conexiones
- Se obtuvo un rendimiento muy elevado tanto en tráfico normal como anómalo




# Capacidad de discriminación del modelo

- La curva ROC permite evaluar la capacidad de clasificación del modelo
- El valor AUC obtenido refleja un rendimiento muy elevado
- Random Forest distingue eficazmente entre tráfico normal y anómalo



# Variables más relevantes

- El modelo identifica qué variables tienen mayor influencia en la clasificación
- Destacan variables relacionadas con volumen de tráfico y comportamiento de conexiones
- El análisis facilita una mejor interpretación del funcionamiento del modelo



# Conclusiones

- Se desarrolló un flujo completo de análisis y Machine Learning aplicado a ciberseguridad
- Los modelos entrenados obtuvieron resultados muy elevados
- Random Forest presentó el mejor rendimiento general
- Las técnicas de evaluación confirmaron la calidad del modelo final
- Machine Learning resulta útil para la detección de intrusiones en red

Gracias por su atención