

## Resumen

El crecimiento y la complejidad del tráfico en Internet exigen mecanismos eficientes de clasificación que mejoren simultáneamente calidad de servicio y seguridad. En este contexto, se propone un modelo de clasificación multiclase basado en aprendizaje profundo integrado a redes definidas por software (SDN), capaz de identificar aplicaciones y ataques a nivel de flujo. Se evaluaron arquitecturas recurrentes (LSTM, BiLSTM, GRU y BiGRU) utilizando conjuntos de datos públicos integrados. Los resultados muestran que el modelo GRU alcanzó una exactitud de 99,65%, validando la viabilidad de la propuesta para su integración en entornos SDN.

## Alcance y Contribuciones

El objetivo de esta investigación es proponer y validar un modelo de clasificación de tráfico en redes definidas por software basado en técnicas de aprendizaje profundo, orientado a mejorar simultáneamente la calidad de servicio y la seguridad mediante la identificación de aplicaciones y ataques a nivel de flujo. Las principales contribuciones pueden resumirse en:

- Identificación de limitaciones actuales en la clasificación de tráfico en entornos SDN, particularmente en escalabilidad, desequilibrio de datos y generalización de modelos.
- Diseño y evaluación comparativa de cuatro arquitecturas recurrentes (GRU, BiGRU, LSTM y BiLSTM) aplicadas a clasificación multiclase basada en flujos.
- Propuesta de un esquema de selección de características obtenibles desde la interfaz norte del controlador SDN, reduciendo dimensionalidad y costo computacional sin degradar la exactitud.
- Integración y validación del modelo en un entorno SDN emulado, demostrando su viabilidad técnica para despliegue en redes reales.

## Modelo de Clasificación de Tráfico SDN

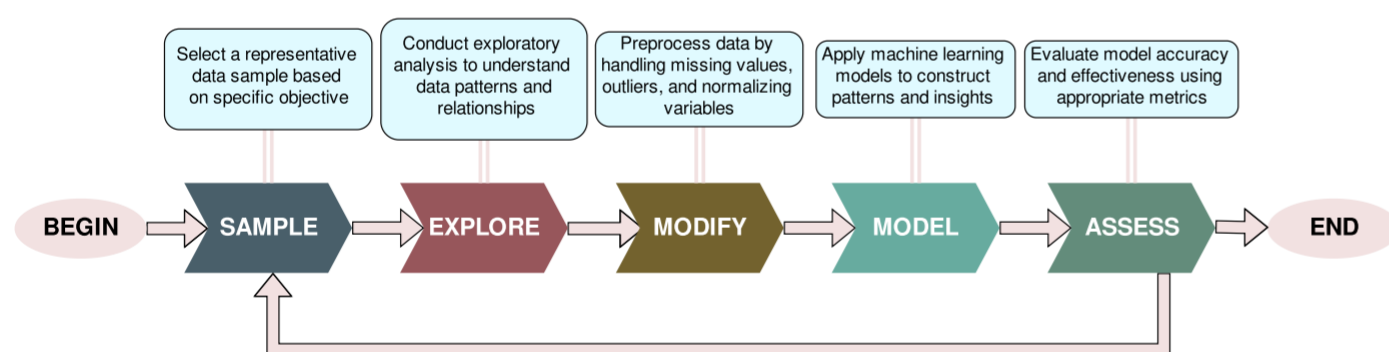


Figure 2. Fases de la metodología SEMMA.

Table 1. Descripción de las características de flujo para el modelo.

No.	Nombre característica	Descripción
1	Flow Duration	Duración del flujo en microsegundos
2	Flow Pkts/s	Número de paquetes de flujo por segundo
3	Flow Byts/s	Número de bytes de flujo por segundo
4	Fwd Pkts/s	Número de paquetes reenviados por segundo
5	Bwd Pkts/s	Número de paquetes de retorno por segundo

Table 2. Comparación de desempeño (5 características)

Modelo	Exactitud	Tiempo (s)	GPU (%)
GRU	<b>99.65%</b>	<b>339</b>	<b>28</b>
LSTM	99.63%	389	33
BiLSTM	99.32%	646	48
BiGRU	98.60%	626	45

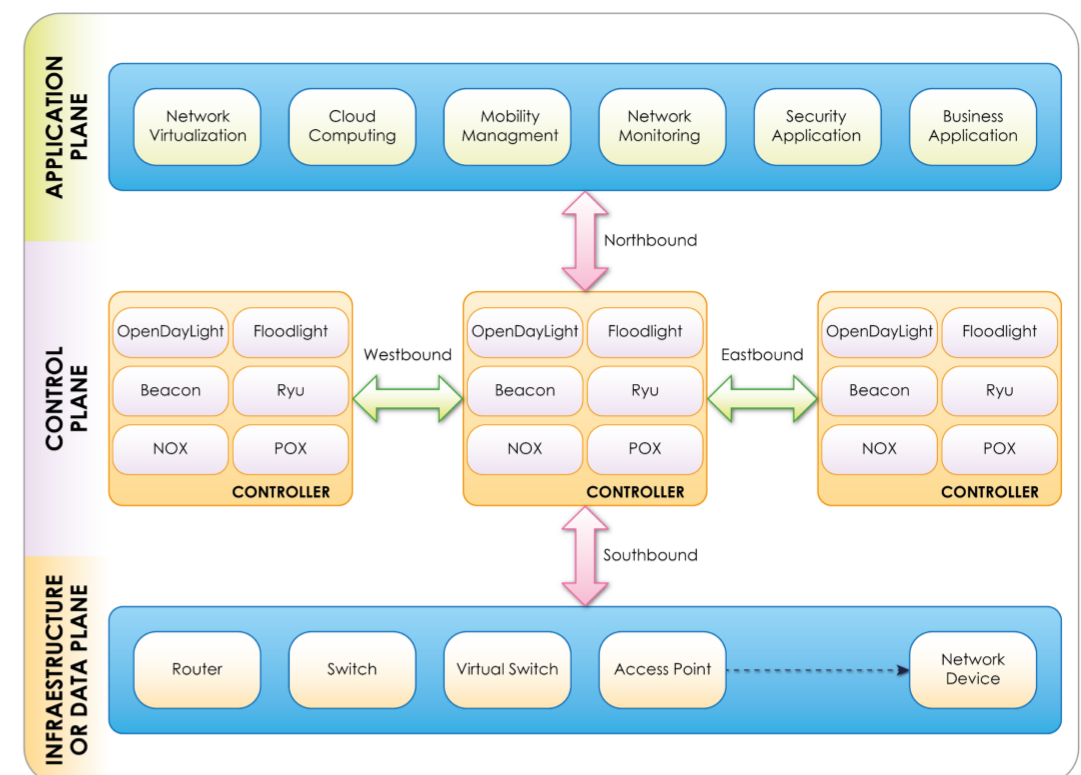


Figure 1. Arquitectura de redes definidas por software.

## Resultados de Implementación del Modelo

El modelo GRU obtuvo el mejor desempeño, con una exactitud de 99,65% en clasificación multiclase con cinco características de flujo, con menor tiempo de entrenamiento y menor uso de GPU que las arquitecturas bidireccionales.




Figure 3. Comparación de la exactitud de los modelos de clasificación.

Entorno de pruebas de concepto en GNS3 con controlador Ryu, Open vSwitch y servidor de aplicaciones para la ejecución de los modelos de clasificación.

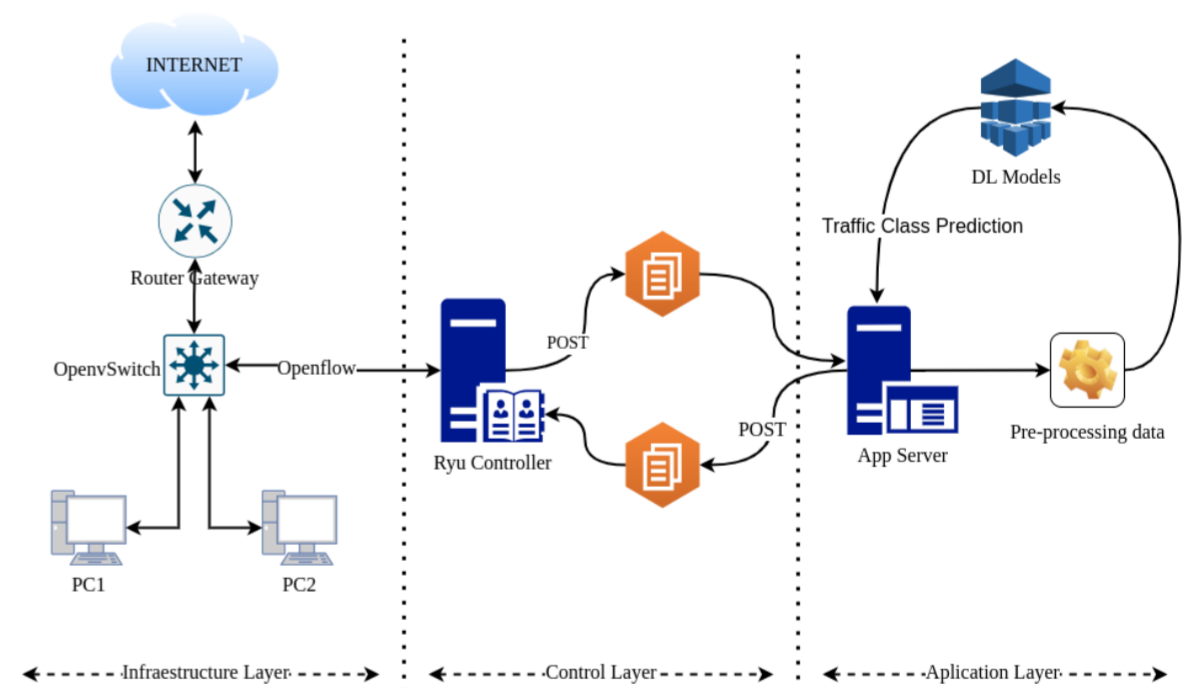


Figure 4. Entorno para la implementación de los modelos de clasificación.

## Conclusion

Se validó un modelo multiclase basado en aprendizaje profundo para clasificación de tráfico en SDN. El modelo GRU alcanzó 99,65% de exactitud, manteniendo alto F1-score en todas las clases. La selección de cinco características redujo la complejidad computacional sin degradar el desempeño.

## Líneas de I+D Futuras

- Validación del modelo en entornos SDN reales con clasificación en tiempo real.
- Construcción de un dataset actualizado con tráfico real para mejorar generalización.
- Exploración de aprendizaje por refuerzo para clasificación adaptativa.