

An Approach Based on Knowledge-Defined Networking for Identifying Video Streaming Flows in 5G Networks

Luis Miguel Castañeda Herrera, Alejandra Duque-Torres, *Student Member, IEEE*, and Wilmar Yesid Campo Muñoz

Abstract—5G aims to provide a complete wireless communication system with various applications, network services and technologies. In terms of 5G network management, Software-Defined Networking (SDN), and Network Functions Virtualization (NFV) are expected to control and manage network resources. Network Softwarization provides better management of network traffic. However, it does not guarantee network performance will not degradation when the traffic rises. Flow identification has been raised as a solution for keeping the network performance, and it has become a hot topic in both, academy and industry. In particular, there is a high interest in identifying video streaming flows since thanks to 5G and its benefits that improve the streaming media industry, the video streaming traffic is expected to increase dramatically due to the massive connection of 5G compatible devices. Motivated by this, we presented a novel approach for identifying video streaming services. Our approach includes three modules: video stream acquisition module, video stream analyzer module, and application module. In the video stream acquisition module, we capture video streaming packets and organize them into flow records. In the video streaming analyzer module, we analyze the flow records using supervised machine learning algorithms to find the appropriate algorithm that performs better. In the application module, we provide a brief explanation of the applications of our approach. Additionally, we provide an analysis of the overall workload generated by our approach. The results of the evaluation by module corroborate the usefulness and feasibility of our approach for identifying video streaming services.

Index Terms—5G, Flow Classification, KDN, SDN, Video Streaming.

I. INTRODUCCIÓN

Las redes inalámbricas de quinta generación (5G) tienen como objetivo soportar una amplia variedad de servicios agrupados en: Banda Ancha Móvil Mejorada (eMBB, *Enhanced Mobile Broadband*), Comunicación Ultra-confiable y de Baja Latencia (URLLC, *Ultra-Reliable Low-Latency Communication*) y Comunicaciones Masivas Tipo Máquina (mMTC, *Massive Machine-type Communication*), las cuales se ejecutarán y compartirán simultáneamente la red física [1], [2]. Así, 5G proporciona un sistema de comunicación inalámbrico completo capaz de soportar diversas aplicaciones y tecnologías, como internet de las cosas (IoT, *Internet of*

Things), redes heterogéneas (HetNets, *Heterogeneous Network*), redes de sensores inalámbricos (WSN, *Wireless Sensor Networks*), paradigmas de Internet del Todo (IoE, *Internet of Everything*), servicios de realidad virtual, entre otros [3]. Esta convergencia de aplicaciones, servicios de red y tecnologías, trae consigo nuevos requerimientos respecto a latencia, confiabilidad, densidad de capacidad y conexión, eficiencia espectral del sistema, eficiencia energética y rendimiento máximo que deben abordarse con la tecnología 5G [4].

Para soportar estos requerimientos, aparecen tecnologías como la *softwarización* que utiliza redes definidas por software (SDN, *Software Defined Network*), *Network slicing* y virtualización de funciones de red (NFV, *Network Functions Virtualization*) [5]. La *softwarización* que ofrece SDN se basa en la separación del plano de control del plano de datos, lo que permite una visualización y control centralizado de los dispositivos de red [6]. *Network slicing* brinda la capacidad de virtualizar la infraestructura subyacente y proporcionar aislamiento entre los servicios en segmentos de red (*slicings*), permitiendo la construcción de múltiples redes lógicas virtualmente independientes, para proporcionar capacidades específicas dentro una única red [7] y NFV consiste en la implementación en software de las funciones de red [5].

El control centralizado de la red proporciona una arquitectura flexible para administrar de manera más eficiente el tráfico de la red, el cual es de gran importancia en 5G debido a la conexión masiva y heterogénea de dispositivos. Sin embargo, esta flexibilidad que trae la *softwarización* a las redes 5G, no garantiza que el rendimiento de la red no se degrade cuando el tráfico aumente [8], [9]. Por ende, la importancia de generar mecanismos de gestión de tráfico de red, e.g., asignación de recursos, enrutamiento dinámico, identificación de flujos, entre otros, permanece prioritario en 5G [10].

En particular la identificación de flujos de red, ha sido objeto de estudio por la academia e industria, debido a su importancia en el mantenimiento del rendimiento de la red [8], [9]. En este mismo orden de ideas, los servicios de videostreaming consumen considerablemente más recursos de red que otros tipos de flujos combinados [11]. Además, según reportes de Cisco [12] y Sandvine [13], más del 80% del tráfico total pertenecen a servicios asociados a videostreaming. Así mismo, según predicciones de Ericsson [14], el 76% de este tráfico será soportado por la redes 5G, y tendrá un crecimiento anual del 30% y un consumo mensual de 124.64 EB para el año 2025 [14]. Para asignar recursos sobre las *network slicing* de

L.M Castañeda Herrera, and W.Y Campo Muñoz are with the Department of Electronic Engineering, Universidad del Quindío, Quindío, Colombia (e-mail: lmcastanedah@uqvirtual.edu.co; wycampo@uniquindio.edu.co)

A. Duque-Torres is with the Institute of Computer Science, University of Tartu, Tartu, Estonia (e-mail: duquet@ut.ee)

manera inteligente y gestionar los flujos de videostreaming dependiendo de los requerimientos por parte de los usuarios y el tipo de servicio que estén consumiendo es necesario primero la identificación de flujos [5], [15].

Los tipos de identificación de flujos más utilizados se basan en el número de puerto, la inspección profunda de paquetes (DPI, *Deep Packet Inspection*), el comportamiento del host y por características del flujo [16]-[20]. Los sistemas de identificación basados en puertos no son confiables porque algunas aplicaciones o servicios utilizan números de puerto no estandarizados o aleatorios [16]. Además, tienen un alto costo de procesamiento y generalmente no se usan porque los contenidos están cifrados [17]. Los mecanismos para identificación de flujos basados en comportamiento del *host*, debido a las asimetrías de enrutamiento que se presentan en el borde de la red, es difícil elegir un punto de medición que garantice la precisión de los datos [18]. Por otro lado, los sistemas de identificación basados en características de flujo aprovechan las ventajas de la información estadística del mismo (*e.g.*, tamaño de flujo, el número de paquetes, duración del flujo). Estas características se pueden extraer durante el establecimiento, mantenimiento y liberación de una sesión, sin embargo, este tipo de clasificador genera una sobrecarga importante en la red [19].

Por lo anterior, de acuerdo a las capacidades que ofrece la *softwarización* de la red a 5G, y la necesidad de contribuir en el ámbito de gestión de redes, en particular, la identificación de flujos de vídeo, en este artículo se propone un mecanismo para la identificación de flujos de vídeo en redes 5G basado en el concepto de redes definidas por conocimiento (KDN, *Knowledge-Defined Networking*). KDN es un concepto de red que aprovecha las técnicas de aprendizaje automático (ML, *Machine Learning*) para mejorar servicios de gestión de red [21], [22].

Como aporte en este artículo, el enfoque propuesto se compone de tres módulos principales: Módulo de Adquisición de Datos de Videostreaming (MAD-V), Módulo ANalizador de Datos de Videostreaming (MAND-V) y Módulo de Aplicación (MAP). En particular, en MAD-V, se hace uso de la herramienta *flowRecorder* [23], que se utilizó para organizar paquetes en registros de flujos. Con esta herramienta, se extraen características estadísticas de los flujos, que pertenecen a tráfico de videostreaming en una red SDN implementada con el *switch SDN Zodiac FX*, el cual es un dispositivo real de bajo costo diseñado para entornos de investigación. Estas características extraídas, se usan para la construcción de un dataset y son validadas con el software *NFStream* [24] con el cual se termina de etiquetar los datos para el dataset.

En MAND-V, se realiza un análisis basado en algoritmos de ML supervisado para construir un modelo que permite identificar flujos de videostreaming, en particular servicios de livestream, vídeo bajo demanda (VoD, *Video on Demand*) y flujos de no vídeo. Además, se utilizan medidas de desempeño derivadas de una matriz de confusión para observar el rendimiento del modelo. En MAP, el controlador recibe las etiquetas de los flujos identificados y determinara que hacer con ellos, para poder enrutar de manera eficiente los flujos de videostreaming. Por último, se realiza una prueba de rendimiento de

uso de CPUs del sistema donde se encuentra el controlador cuando entra en funcionamiento MAND-V y se observa que el controlador se libera de las tareas de clasificación, por lo que puede usar esos recursos en otras tareas de gestión mejorado así el rendimiento de la red. Además, los resultados de la evaluación por módulo muestran la utilidad y la viabilidad de este enfoque basado en KDN para identificar videostreaming de forma inteligente.

El resto de este artículo está organizado de la siguiente manera: En la Sección II se ofrece una descripción de los aspectos fundamentales sobre los que se basa el enfoque propuesto. En la Sección III se presentan trabajos relacionados para la identificación de videostreaming mientras que en la Sección IV se muestra en detalle cada uno de los módulos propuestos. Luego, en la sección V se presenta el análisis de los resultados de la evaluación del enfoque propuesto. Por último, se presentan las conclusiones y los trabajos futuros en la Sección VI.

II. MARCO TEÓRICO

En esta sección, se presentan los conceptos teóricos principales en los que se enmarca esta propuesta, como son: videostreaming, SDN (arquitectura y características principales), ML y KDN.

A. Videostreaming

En un servicio de videostreaming, una sesión inicia con una solicitud por parte de un cliente a un servidor, posteriormente el servidor envía la información la cual se va almacenando en un búfer en el cliente y es seguida por una fase de estado estable. Durante la fase de almacenamiento en búfer, la transferencia de datos está limitada por el ancho de banda disponible, en esta fase se guarda una cierta cantidad de datos antes de reproducir el vídeo. Luego, en la fase de estado estable se presentan unos ciclos *ON-OFF*, que se utilizan para limitar la velocidad de descarga, si la tasa de descarga promedio es ligeramente más alta que la tasa de codificación de vídeo, el vídeo se pausará. La relación entre estas dos tasas se conoce como tasa de acumulación, y su valor debe ser mayor a 1, para permitir la reproducción de vídeo sin interrupciones [25].

B. Redes Definidas por Software (SDN, *Software-Defined Networking*)

La arquitectura SDN comprende cuatro planos [26], [27]: plano de datos, plano de control, plano de aplicación y plano de gestión. El plano de datos incluye los dispositivos de reenvío interconectados. Estos dispositivos suelen estar compuestos por hardware de reenvío programable. Además, tienen conocimiento local de la red y confían en el plano de control para completar sus tablas de reenvío y actualizar su configuración [28]. El plano de control consta de una o más interfaces hacia el norte (NBI, *NorthBound Interface*), el controlador SDN y una o más interfaces hacia el sur (SBI, *SouthBound Interface*). Las NBI permiten que el plano de control se comunique con el plano de aplicación. El controlador

es responsable de programar los elementos de reenvío a través de una SBI [28]. El plano de aplicación incluye programas de requisitos y comportamiento de red deseado al controlador SDN a través de una NBI. Por último, el plano de gestión recopila información de telemetría del plano de datos mientras mantiene un registro histórico del estado y los eventos de la red [29].

C. Aprendizaje Automático (ML, Machine Learning)

El aprendizaje automático, es una rama de la Inteligencia Artificial (IA) que incluye un conjunto de métodos para detectar automáticamente patrones en estructuras de datos. Estos métodos permiten tomar decisiones basándose únicamente en los datos analizados [22]. En el contexto de la red, surgen algunas posibilidades del uso de ML [20]: *i*) comportamiento en la red, *ii*) detección de anomalías, *iii*) identificación de tráfico y clasificación de flujos; y *iv*) asignación adaptativa de recursos.

En general, ML se puede dividir en aprendizaje supervisado (SL, *Supervised Learning*), aprendizaje no supervisado (UL, *Unsupervised Learning*). SL se enfoca en modelar las relaciones de entrada-salida a través de conjuntos de datos de entrenamiento etiquetados. Normalmente, SL se utiliza para resolver problemas de clasificación y regresión relacionados con los resultados del pronóstico. Por ejemplo, la predicción de tráfico [30] o la carga de un enlace [31]. A diferencia de SL, UL utiliza conjuntos de datos de entrenamiento sin etiquetar para crear modelos que pueden discriminar patrones en los datos. Este tipo de aprendizaje es más adecuado para problemas de agrupación. Por ejemplo, clasificación de tráfico basada en características de flujo [32], estimación de pérdida de paquetes [33] y asignación de recursos [34].

D. Redes Definidas por el Conocimiento (KDN, Knowledge-Defined Networking)

En 2003, Clark y Col [21], sugirieron la adición de un plano de conocimiento (KP, *Knowledge Plane*), a la arquitectura de red de computadoras tradicional formada por el plano de control y el plano de datos [28]. KP adopta la inteligencia artificial para darle a un sistemas una capacidad de razonar, descubrir, generalizar o aprender de experiencias pasadas [22]. Para lograr estas habilidades, KP propone el uso de técnicas de ML. Para procesos de automatización, sistemas de recomendación y predicción de datos. Estas ventajas brindan la posibilidad de tener una operación y gestión de red inteligente [29].

La adición de KP a la arquitectura SDN se denomina KDN [29], el uso de KP, da la posibilidad de mejorar la forma de operar y solucionar problemas de redes SDN. Ya que, SDN ofrece una visión de red completa a través de un controlador centralizado lógicamente [29]. Además, las capacidades de los dispositivos de las redes, facilitan la recopilación de información sobre los paquetes y tiempo de procesamiento [28].

KDN consta de cuatro planos: plano de datos, plano de control, plano de gestión y KP. El plano de datos es responsable de generar metadatos por parte de los dispositivos de red

de reenvío. El plano de control proporciona las interfaces para recibir las instrucciones del KP; luego, el controlador transmite las instrucciones a los dispositivos de reenvío. Además, el plano de control envía metadatos al plano de gestión sobre el estado de la red. En el plano de gestión, los metadatos de los planos de datos y control se recopilan y almacenan. El plano de gestión proporciona un análisis básico de estadísticas por flujo y por dispositivos de reenvío al KP. Finalmente, KP envía al controlador un conjunto de instrucciones sobre lo que debe hacer la red [35].

III. TRABAJOS RELACIONADOS

Existe un interés creciente en la investigación de los mecanismos de clasificación de tráfico (TC, *Traffic Classification*), debido a que es un pilar importante para realizar actividades de gestión de una manera eficaz y eficiente. Un tratamiento inadecuado del tráfico es uno de los factores que impactan en el desempeño de las tareas de gestión, incluyendo anomalías de la red, seguridad, ingeniería de tráfico, calidad de servicio, aprovisionamiento de recursos y detección de violaciones. Además, el tráfico continúa creciendo exponencialmente en tamaño por la masiva conexión de dispositivos. Donde, la mitad de este tráfico en la red, proviene de dos distribuidores de servicios OTT (*Over The Top*), como *Netflix* y *Youtube* [13]. También, los servicios de videostreaming se acercan al 80% de todo el tráfico presente en las redes [12], donde el 76% se espera sea soportado por la redes 5G para el año 2025 [14]. Por lo tanto, el funcionamiento y la gestión de los servicios de videostreaming se está volviendo cada vez más complejo y crucial para garantizar una buena gestión de red.

Pese a las ventajas en cuanto al incremento en ancho de banda en redes 5G, sigue siendo necesario la gestión del tráfico de videostreaming, puesto que este sigue creciendo de manera exponencial. Uno de los pilares de desarrollo de la tecnología 5G son las redes definidas por software que brindan una visión global de la red, mejorando la gestión del tráfico, a través de la construcción de redes lógicas virtuales, redireccionamiento de tráfico y extracción de estadísticas [35].

Aprovechando esto, algunas investigaciones proponen una clasificación de tráfico basada en ML, como una solución para el etiquetado de paquetes y la búsqueda de servicios de aplicaciones en la gestión red, creando modelos basados en estadísticas, que pueden mostrar la distribución global de las características de un tráfico en SDN [36]-[39]. Sin embargo, en estas investigaciones se enfocan en redes tradicionales o en la clasificación de todo tipo de tráfico y no se enfocan en el impacto de los servicios de videostreaming en las redes. Los cuales son más complejos, porque es necesario garantizar la calidad del servicio por un tiempo considerable para garantizar una buena transmisión con respecto a servicios tradicionales [25], [40]. Por lo tanto, en este artículo se presenta un enfoque de clasificación de tráfico usando KDN para estudiar y clasificar servicios livestream, VoD y flujos de no vídeo en un entorno 5G.

IV. ENFOQUE PROPUESTO

Pese a la gran capacidad de recursos que ofrece 5G, la escalabilidad y la gestión del tráfico son y seguirán siendo

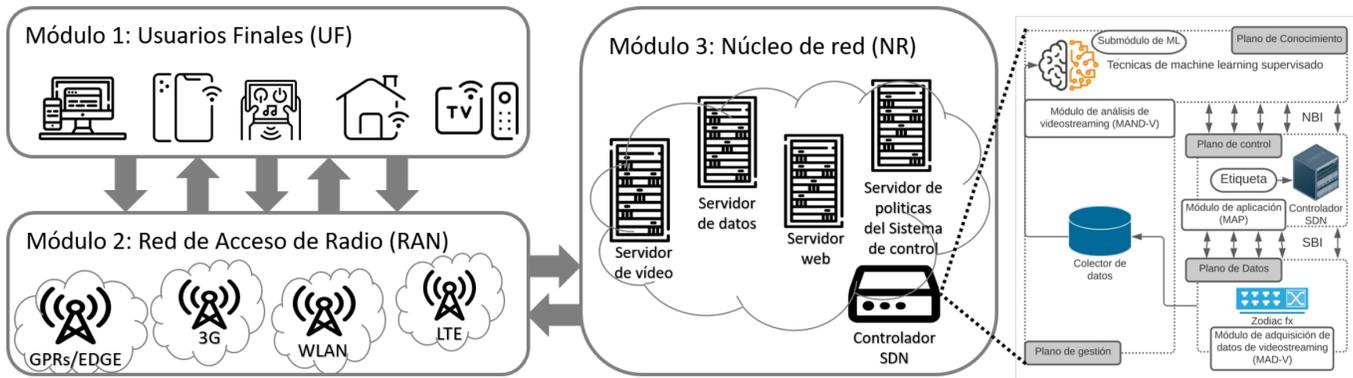


Fig. 1. Enfoque propuesto para clasificación de videostreaming en redes 5G.

un desafío, por lo que se deben buscar nuevas estrategias o alternativas para el manejo de grandes volúmenes de información, la gestión de los recursos y el control del tráfico de servicios de videostreaming. Por este motivo, se presenta un enfoque novedoso que contribuye a la gestión del tráfico y la viabilidad de utilizar el concepto KDN en identificar servicios de videostreaming. La Fig. 1, muestra un esquema conceptual del enfoque propuesto donde se pueden identificar 3 módulos claramente definidos: MAD-V, MAND-V y MAP. El módulo MAD-V envía paquetes capturados a MAND-V. El módulo MAND-V es responsable de organizar los paquetes en flujos, y a su vez se encarga de generar un modelo del estado de la red. Finalmente, el controlador obtiene las etiquetas de los flujos clasificados y en el módulo MAP se instruyen las nuevas configuraciones de red a los dispositivos de reenvío. En general, el enfoque propuesto opera de la siguiente manera:

1. *Dispositivos de reenvío* → *punto de Observación*. En el punto de observación se realiza la captura de paquetes con el software *Wireshark*, que atraviesan algún dispositivo de reenvío de datos. Estos paquetes se pueden extraer, por ejemplo, de alguna tarjeta de red que funciona como punto de observación. Antes de comenzar a enviar los paquetes al colector de datos, los paquetes se pueden preprocesar mediante reglas de muestreo y filtrado.
2. *Punto de observación* → *Colector de datos*. En el colector de datos, los paquetes proporcionados por el MAD-V se organizan y almacenan en flujos. Tiene como objetivo recopilar suficiente información para ofrecer una visión global del comportamiento de los flujos de videostreaming en la red.
3. *Colector de datos* → *Submódulo ML*. El submódulo de ML hace uso de técnicas de ML supervisadas con datos históricos o actuales provenientes del colector de datos para crear modelos de comportamiento de los flujos y así generar conocimiento, por ejemplo, un modelo del comportamiento de los servicios de videostreaming que puede ser usado para predecir datos futuros, el rendimiento de los modelos se determinan por las medidas de desempeño derivadas de una matriz de confusión.
4. *Submódulo de ML* → *Clasificación de Videostreaming* → *Controlador SDN*. MAP facilita la transición entre el modelo generado por el submódulo de ML y el

controlador. Según el bucle de control KDN, este paso puede estar abierto o cerrado. Si el administrador es responsable de decidir sobre la red, el circuito de control está abierto. En este caso, MAP ofrece validaciones y recomendaciones, que el administrador puede considerar a la hora de tomar decisiones. Por ejemplo, en un caso de control de congestión, el administrador puede consultar el modelo de clasificación de videostreaming, para validar los cambios provisionales en la configuración antes de aplicarlos a la red. En el circuito de control cerrado, el administrador no es responsable de decidir sobre la red. En este caso, el modelo obtenido del submódulo de ML se puede utilizar para automatizar tareas, ya que MAP puede tomar decisiones automáticamente en nombre del administrador. Además, el modelo se puede utilizar para optimizar la configuración de red existente [34]. Por ejemplo, el modelo puede aprender de forma adaptativa según el cambio de tráfico y encontrar la configuración óptima para enrutar los flujos de videostreaming y, por lo tanto, evitar la congestión.

A. Módulos y Arquitectura

En la Fig. 2, se presenta la arquitectura y los módulos del enfoque basado en KDN para la clasificación de videostreaming de manera inteligente. Esta arquitectura incluye los cuatro planos KDN, los cuales son, datos, control, gestión y conocimiento. KP incluye las técnicas ML del módulo MAND-V con el objetivo de generar un modelo para agrupar servicios de livestream, VoD y no vídeo. El plano de control es responsable de enrutar los flujos de acuerdo con las decisiones tomadas por el módulo MAP. Además, el plano de control envía información al plano de gestión sobre el estado de la red, incluidas las estadísticas de flujos que se utilizan en la creación del modelo de ML con algoritmos basados en aprendizaje supervisado. En el plano de gestión, la información de los planos de control y de datos se recopila y almacena. El plano de gestión realiza un análisis básico de estadísticas por flujo y por dispositivos de reenvío utilizando el colector de datos del módulo MAND-V. El plano de datos es responsable de generar información por los dispositivos de red de reenvío, esta información se extrae y se transmite al plano de gestión. El plano de datos está formado por los dispositivos de red y

el módulo MAD-V. Las siguientes subsecciones detallan los módulos antes mencionados.

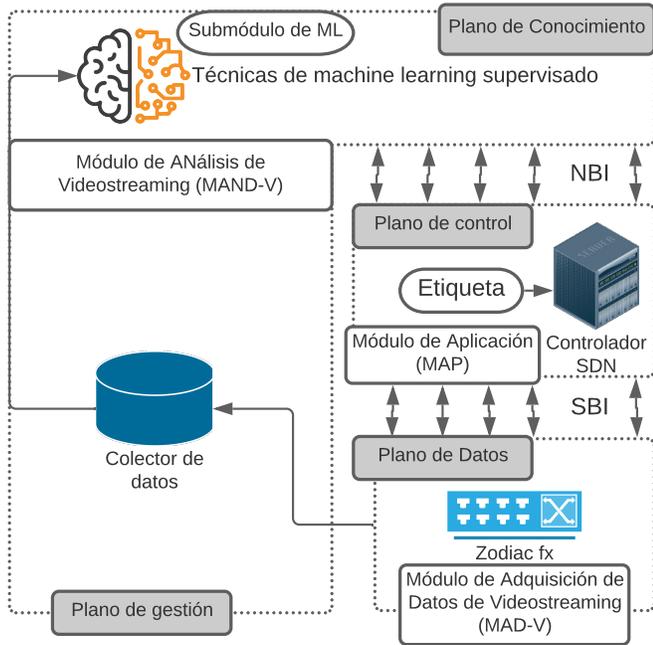


Fig. 2. Arquitectura funcional para la clasificación de videostreaming en 5G.

B. Módulo de Adquisición de Datos de Videostreaming

MAD-V es responsable de realizar dos tareas. En primer lugar, captura paquetes desde algún punto de observación en los dispositivos de red, en este caso el *Zodiac FX*. En segundo lugar, se genera un conjunto de datos para la identificación de videostreaming a partir de los paquetes recopilados y sus estadísticas. En MAD-V, se construye el conjunto de datos para identificación de videostreaming a partir de un rastro de tráfico recopilado en un entorno SDN controlado, denominada *Datavideo*. *Datavideo* se procesó y se organizó en instancias que representan un flujo utilizando la herramienta *flowRecorder* [23], que permite convertir paquetes IP, ya sea en forma de archivos PCAP (*Packet CAPture*) o analizados en vivo desde una interfaz de red, en registros de flujo que se almacenan en un archivo de valores separados por comas (CSV, *Comma Separated Values*). *FlowRecorder* admite la medición de características de flujo tanto en modo unidireccional como bidireccional. Dependiendo de las propiedades de los paquetes observados (entrantes), se crean nuevos registros de flujo o se actualizan las características de los flujos existentes, los datos obtenidos por *flowRecorder* fueron validados con otro software llamado *NFStream* [24], el cual puede realizar las mismas tareas que *flowRecorder*, pero tiene como ventaja el uso de nDPI (*openN source library for Deep-Packet Inspection*) que permite extraer información de la capa 7 de los flujos y verificar a que aplicación pertenece cada flujo, bien sea, de *livestream*, *VoD* o *no-vídeo*, con la ayuda de *NFStream* se etiquetan los flujos en el dataset para usarlo posteriormente en el submódulo de ML.

TABLA I
DESCRIPCIÓN DEL DATASET.

Característica	Descripción
src-ip	Dirección IP fuente
dst-ip	Dirección IP destino
f-pktTotalCount	Número de paquetes transmitidos (Ida)
b-pktTotalCount	Número de paquetes transmitidos (Regreso)
f-octetTotalCount	Número de Bytes transmitidos (Ida)
b-octetTotalCount	Número de Bytes transmitidos (Regreso)
f-avg-piat	Tiempo medio de llegada entre paquetes (Ida)
b-avg-piat	Tiempo medio de llegada entre paquetes (Regreso)
f-avg-ps	Tamaño medio de paquetes (Ida)
b-avg-ps	Tamaño medio de paquetes (Regreso)
src-port	Puerto fuente
dst-port	Puerto destino
proto	Identificador de protocolo (e.g. TCP/UDP)
Clase	Clasificación de la instancia

C. Módulo de Análisis de Videostreaming

MAND-V funciona de dos modos, un modo *offline* y otro *online*, en general MAND-V se encarga de almacenar y generar un modelo de las características de los flujos para luego poder identificar los flujos de videostreaming de manera inteligente con un submódulo de ML. Para realizar esta tarea primero MAND-V en su modo *offline* recibe la información proveniente de un punto de observación de MAD-V a un colector de datos, que organiza los paquetes que captura, en flujos ordenados y extrae sus características en un archivo CSV, con el cual se crea *Datavideo*, que contiene información de 1200 instancias donde cada una representan un flujo. 400 de servicios de *livestream*, 400 de *VoD* y 400 para flujos de no vídeo. Este dataset se usa para entrenar y crear uno o varios modelos de ML con las características que se presentan en la Tabla I. Luego, con ayuda del modelo que presente el mejor resultado, MAND-V en su modo *online*, al extraer las características de los flujos de tráfico *online* que vienen del punto de observación, realiza su posterior clasificación, etiquetando los flujos con el número 1 para servicios de *livestream*, 2 para *VoD* y 3 para los flujos de no vídeo. Cabe mencionar que *flowRecorder* se usó como colector de datos y *Nfstream* como submódulo de ML.

D. Módulo de Aplicación

MAP es responsable de enviar instrucciones al controlador SDN, sobre lo que necesita hacer. Por ejemplo, cuando se identifica un servicio de videostreaming y otro que no. Una vez identificado el flujo de videostreaming se marca con una etiqueta y el controlador se encargara de instruir o darles órdenes a los dispositivos de reenvío sobre el manejo de ese flujo, realizando una variedad de actividades relacionadas con tareas de gestión y así mejorar el rendimiento general de la red. Para llevar a cabo los experimentos se usó el controlador *OpenDaylight* [41], debido a que es un controlado de fácil acceso e implementación con el *Zodiac Fx*.

V. ANÁLISIS Y RESULTADOS

Para evaluar el mecanismo propuesto primeramente, en [42] se hace una comparación de rendimiento de diferentes modelos de ML, los cuales son, regresión logística (LoR, *Logistic*

Regression), Análisis Discriminante Lineal (ADL), *k*-vecinos más cercanos (*k*-NN, *k*-Nearest-Neighbor), *Naive Bayes* (NB) y árboles de decisión (CART, *Classification And Regression Tree*). Para observar el rendimiento de los modelos, se realizó una validación cruzada, donde se usaron datos de validación al 30% de los datos originales presentes en Datavideo. El modelo con el mejor rendimiento fue CART con un *accuracy* de 90% seguidos de *k*-NN con 86% y LoR con 83.9% como se observa en la Tabla II, estos resultados se puede observar con más detalle en [42].

TABLA II
DESEMPEÑO DE MODELOS DE ML.

	Accuracy	Parametros
CART	90 %	Profundidad=10, Criterion=entropy
k-NN	86 %	# de Vecinos=7, Algorithm=kd-tree
LoR	83.9 %	Max-iter=1000

Después, para ver el rendimiento en detalle del modelo que presento un mejor resultado, en este caso CART, se utilizaron medidas de desempeño derivadas de la matriz de confusión, ver Tabla III. Donde A y A' denotan una clasificación (por ejemplo, un flujo de livestreaming) y el subíndice de $C(n)$ denota el numero asignado a cada clase, donde 1 es livestream, 2 es VoD y 3 no vídeo. Luego cada medida estándar de referencia se expresa como una función de la matriz de confusión definida de la siguiente manera:

Verdadero Positivo (VP): Si la clase actual de un caso fue A y la clase predicha fue A . Esto representa una predicción exitosa.

Verdadero Negativo (VN): Si la clase actual de un caso fue A' y la clase predicha fue A' . Esto representa una predicción exitosa.

Falso Positivo (FP): Si la clase actual de un caso fue A' y la clase predicha fue A . Esto representa una predicción errónea.

Falso Negativo (FN): Si la clase actual de un caso fue A y la clase predicha fue A' . Esto representa una predicción errónea.

Las medidas de desempeño vienen dadas por tres métricas, precisión, sensibilidad y puntaje F1. La precisión se refiere a la dispersión del conjunto de valores obtenidos a partir de mediciones repetidas de una magnitud. La sensibilidad es la tasa de verdaderos positivos y el puntaje F1 indica si un modelo tiene una buena precisión y fiabilidad. Como se observa en la Tabla III, el modelo clasifica entre flujos de videostreaming y flujos que no son de vídeo sin ningún problema, hay un total de 99 instancias correctamente clasificadas para livestream, 113 para VoD y para la clase 3 un total de 117 verdaderos negativos con un puntaje F1 de 0.98, como se ve en la Tabla III y IV. La diferencia que se destaca entre flujos de vídeo o no vídeo, radica principalmente en la cantidad de paquetes y la cantidad de bytes transmitidos, aunque los datos sean capturados en intervalos de pocos segundos, estos flujos siguen siendo mayores que los flujos de control o de otros servicios, porque los servicios de vídeo tienen una propiedad intrínseca y es el uso de búferes. Al comienzo de una sesión, estos búferes tienen un tamaño ya considerable, comparándolo con

TABLA III
MATRIZ DE CONFUSIÓN ENTRE INSTANCIAS CLASIFICADAS POR EL MODELO IMPLEMENTADO.

Matriz de confusión por C_n			C_1 vs C_2		
$A' \setminus A$	C_n	Non- C_n	$A' \setminus A$	C_1	C_2
C_n	VP	FP	C_1	99	19
Non- C_n	FN	VN	C_2	7	113

C_2 vs C_3			C_1 vs C_3		
$A' \setminus A$	C_2	C_3	$A' \setminus A$	C_1	C_3
C_2	113	0	C_1	99	1
C_3	1	117	C_3	3	117

otros servicios. Por lo tanto, simplifica la clasificación entre un servicio de videostreaming y un flujo de no vídeo.

Sin embargo, el modelo comienza a bajar su rendimiento al clasificar entre livestream y VoD, donde 7 instancias de livestream fueron catalogadas como VoD siendo falsos negativos y 19 instancias de VoD como falsos positivos, esto implica que aunque la clase 1 muestra una buena precisión, la sensibilidad cae a 0.83 y en la clase 2 la precisión baja a 0.83, como se observa en la Tabla IV. Esto significa que cuando el modelo predice, es preciso, (hay una baja dispersión de los datos predichos). Pero le cuesta diferenciar entre los dos tipos de servicios, VoD o livestream. Por lo demás, el modelo tuvo buenos resultados en general donde se presentan unos niveles de sensibilidad altos, lo que indica que el modelo discrimina de manera correcta los positivos de los negativos de las instancias clasificadas y al observar el puntaje F1 de 0.87, 0.89 y 0.98 para la Clase 1, 2 y 3 respectivamente, se observa un buen rendimiento general del modelo.

TABLA IV
MEDIDAS DE DESEMPEÑO DEL MODELO.

	Clase 1	Clase 2	Clase 3
Precisión	0.91	0.83	0.99
Sensibilidad	0.83	0.94	0.97
Puntaje F1	0.87	0.89	0.98

Por último, se realizó una prueba para ver el rendimiento del enfoque propuesto en cuanto a la carga de trabajo de procesamiento del sistema, donde se encuentra el controlador, implementado en una CPU Core i7 con 6 GB de RAM y un sistema operativo Ubuntu 18.08, para observar la viabilidad de esta propuesta. En la Fig. 3, se presenta el rendimiento de las CPUs del procesador, donde se puede observar un promedio del 20% de su uso, cuando el enfoque propuesto entra a operar como se observa en la Fig. 4, la carga de trabajo aumenta entre un 40% y 50%. Pero, este aumento del uso de las CPUs se debe a las tareas normales que tiene el controlador en cuanto a tareas de enrutamiento, cuando empieza el proceso de clasificación por MAND-V las CPUs se mantienen en el mismo promedio, esto se debe que ahora el controlador ya no va tener que usar recursos para las tareas de clasificación y el rendimiento de clasificación dependerá totalmente de donde se implemente MAND-V, bien sea un servidor, una maquina virtual o una nube. En este caso MAND-V se implemento en una maquina virtual, liberando así al controlador de cargas de trabajo que puede usar en otras tareas de gestión y en

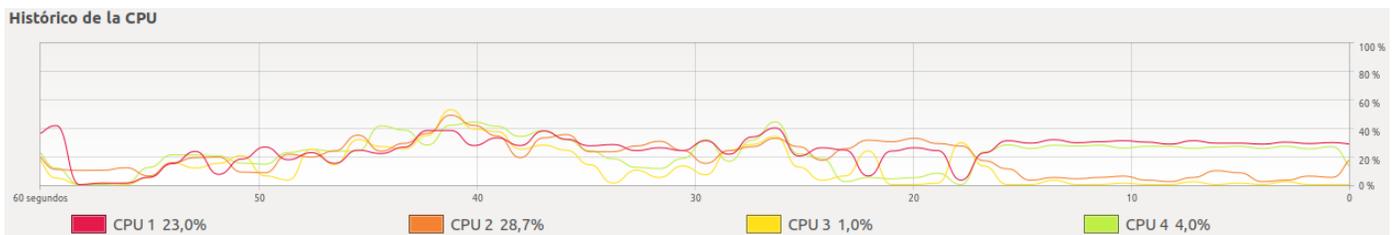


Fig. 3. Carga de trabajo de las CPUs del procesador Core I7 sin el controlador SDN.



Fig. 4. Carga de trabajo de las CPUs del procesador Core I7 con el controlador SDN.

adición a la precisión del modelo en el módulo MAND-V y la reducción de uso recursos en el controlador para tareas de clasificación, los resultados obtenidos corroboran la utilidad y viabilidad de esta propuesta para la clasificación de servicios de videostreaming.

VI. CONCLUSIONES

Teniendo en cuenta las tendencias actuales en las redes, y más aún con la llegada de 5G el consumo de los servicios de videostreaming continuara creciendo. Por este motivo en este artículo se propuso un enfoque de identificación de videostreaming basado en el concepto KDN, con el objetivo de disminuir la carga de trabajo del controlador liberándolo de las tareas de clasificación y así mejorar el rendimiento de la red. Además, se probaron varios modelos de ML supervisado, donde el modelo CART presento los mejores resultados. Por último, se realizó una prueba de rendimiento de las CPUs del procesador donde se encuentra el controlador SDN.

En los resultados obtenidos se observa que el modelo de árboles de decisión es capaz de diferenciar entre flujos de videostreaming y no vídeo sin ningún problema, pero comienzan a disminuir su rendimiento cuando aparece otro servicio como livestream, lo que implica que hay una similitud en cuanto estadísticas de este servicio con VoD. Sin embargo, se puede observar que el modelo tiene una precisión general buena para cada una de las clases con 0.91 para livestream, 0.83 para VoD y 0.99 para no vídeo. Otro resultado, es que, al observar el rendimiento de las CPUs, cuando entra a funcionar el enfoque propuesto, se determina que el rendimiento del controlador no se ve afectado ya que todas las tareas de clasificación de los flujos, dependen de donde este implementado MAND-V. En general, los resultados de la evaluación del enfoque propuesto corroboran su utilidad y viabilidad para la clasificación de servicios de videostreaming y su escalabilidad para implementarse en entornos de redes 5G.

Como trabajo futuro, se plantea la adición de diferentes mecanismos de ingeniería de tráfico, que permita al controlador una vez identificado un servicio de videostreaming tomar

decisiones sobre que hacer con cada flujo. Ya que, en general en todas las redes los servicios de videostreaming seguirán en constante crecimiento en cuanto a su demanda y una mayor exigencia de calidad de servicios, por lo tanto, es importante una correcta gestión de estos servicios .

REFERENCIAS

- [1] L. Bonati, M. Polese, S. D'Oro, S. Basagni y T. Melodia, "Open, Programmable, and Virtualized 5G Networks: State-of-the-Art and the Road Ahead," *Computer Networks*, vol. 182, pág. 107-166, 2020.
- [2] N. Slamnik-Kriještorac, H. Krešo, M. Ruffini y J. M. Marquez-Barja, "Sharing Distributed and Heterogeneous Resources toward End-to-End 5G Networks: A Comprehensive Survey and a Taxonomy," *IEEE Communications Surveys Tutorials*, vol. 22, n.º 3, págs. 1592-1628, 2020.
- [3] L. V. Le, B.-S. Lin y D. Sinh, "Applying Big Data, Machine Learning, and SDN/NFV for 5G Early-Stage Traffic Classification and Network QoS Control," *Transactions on Networks and Communications*, vol. 6, abr. de 2018.
- [4] P. Pirinen, "A brief overview of 5G research activities," en *1st International Conference on 5G for Ubiquitous Connectivity*, 2014, págs. 17-22.
- [5] J. Ordóñez-Lucena, P. Ameigeiras, D. Lopez, J. J. Ramos-Munoz, J. Lorca y J. Folgueira, "Network Slicing for 5G with SDN/NFV: Concepts, Architectures, and Challenges," *IEEE Communications Magazine*, vol. 55, n.º 5, págs. 80-87, 2017.
- [6] B. J. van Asten, N. L. M. van Adrichem y F. A. Kuipers, *Scalability and Resilience of Software-Defined Networking: An Overview*, 2014.
- [7] M. Conoluci y T. Mahmoodi, "Softwarization and virtualization in 5G mobile networks: Benefits, trends and challenges," *Computer Networks*, vol. 146, sep. de 2018.
- [8] D. Awduche, A. Chiu, A. Elwalid, I. Widjaja y X. Xiao, "Overview and Principles of Internet Traffic Engineering," *RFC*, vol. 3272, págs. 1-71, 2002.
- [9] A. Callado, C. Kamienski, G. Szabo, B. P. Gero, J. Kelner, S. Fernandes y D. Sadok, "A Survey on Internet Traffic Identification," *IEEE Communications Surveys Tutorials*, vol. 11, n.º 3, págs. 37-52, 2009.
- [10] M. Hayes, B. Ng, A. Pekar y W. K. G. Seah, "Scalable Architecture for SDN Traffic Classification," *IEEE Systems Journal*, vol. 12, n.º 4, págs. 3203-3214, 2018.
- [11] H. Feng-Hui, Z. Wen-An y D. Yu, "QoE Issues of OTT Services over 5G Network," en *2014 Ninth International Conference on Broadband and Wireless Computing, Communication and Applications*, 2014, págs. 267-273.

- [12] Cisco, "Cisco Visual Networking Index: Forecast and Trends, 2017-2022," *Cisco*, n.º Feb, pág. 147, 2019, [Online]. Available: <https://davidellis.ca/wp-content/uploads/2019/05/cisco-vni-feb2019.pdf>.
- [13] Sandvine, "Global Internet Phenomena Report 2019," *Sandvine*, pág. 23, 2019, [Online]. Available: <https://www.sandvine.com/global-internet-phenomena-report-2019>.
- [14] Ericsson, "Ericsson Mobility Report," *Ericsson*, n.º June, pág. 36, 2020, [Online.] Available: <https://www.ericsson.com/49da93/assets/local/mobility-report/documents/2020/june2020-ericsson-mobility-report.pdf>.
- [15] X. Foukas, G. Patounas, A. Elmokashfi y M. K. Marina, "Network Slicing in 5G: Survey and Challenges," *IEEE Communications Magazine*, vol. 55, n.º 5, págs. 94-100, 2017.
- [16] Y. Dhote, S. Agrawal y A. J. Deen, "A Survey on Feature Selection Techniques for Internet Traffic Classification," en *2015 International Conference on Computational Intelligence and Communication Networks (CICN)*, 2015, págs. 1375-1380.
- [17] M. Finsterbusch, C. Richter, E. Rocha, J. Muller y K. Hanssgen, "A Survey of Payload-Based Traffic Classification Approaches," *IEEE Communications Surveys Tutorials*, vol. 16, n.º 2, págs. 1135-1156, 2014.
- [18] Y. Hou, H. Huang y W. Shao, "Traffic Classification Method by Combination of Host Behaviour and Statistical Approach," *Journal of Engineering Science and Technology Review*, vol. 7, págs. 151-157, jul. de 2014.
- [19] T. Bakhshi, "Multi-feature Enterprise Traffic Characterization in OpenFlow-based Software Defined Networks," en *2017 International Conference on Frontiers of Information Technology (FIT)*, 2017, págs. 23-28.
- [20] R. Boutaba, M. Salahuddin, N. Limam, S. Ayoubi, N. Shahriar, F. Estrada-Solano y O. Caicedo Rendon, "A Comprehensive Survey on Machine Learning for Networking: Evolution, Applications and Research Opportunities," *Journal of Internet Services and Applications*, vol. 9, mayo de 2018.
- [21] D. D. Clark, C. Partridge, J. C. Ramming y J. T. Wroclawski, "A Knowledge Plane for the Internet," ép. SIGCOMM '03, Karlsruhe, Germany: Association for Computing Machinery, 2003.
- [22] C. M. Bishop y N. Nasrabadi, "Pattern Recognition and Machine Learning," *J. Electronic Imaging*, vol. 16, pág. 049901, 2007.
- [23] A. Pekar y A. Duque, "A Network Traffic Flow Feature Measurement Tool," (2018, Nov). v1.1.2 [Online]. Available: <https://github.com/drnpkr/flowRecorder2018>.
- [24] N. Developers, "Flexible Network Data Analysis Framework," (2020, Nov. 15). v6.2.3 [Online]. Available: <https://www.nfstream.org/>.
- [25] K. L. Dias, M. A. Pongelupe, W. M. Caminhas y L. de Errico, "An innovative approach for real-time network traffic classification," *Computer Networks*, vol. 158, págs. 143-157, 2019.
- [26] J. A. Wickboldt, W. P. De Jesus, P. H. Isolani, C. B. Both, J. Rochol y L. Z. Granville, "Software-defined networking: management requirements and challenges," *IEEE Communications Magazine*, vol. 53, n.º 1, págs. 278-285, 2015.
- [27] F. Estrada-Solano, A. Ordonez, L. Z. Granville y O. M. Caicedo Rendon, "A framework for SDN integrated management based on a CIM model and a vertical management plane," *Computer Communications*, vol. 102, págs. 150-164, 2017.
- [28] D. Kreutz, F. M. V. Ramos, P. E. Veríssimo, C. E. Rothenberg, S. Azodolmolky y S. Uhlig, "Software-Defined Networking: A Comprehensive Survey," *Proceedings of the IEEE*, vol. 103, n.º 1, págs. 14-76, 2015.
- [29] A. Mestres, A. Rodriguez-Natal, J. Carner, P. Barlet-Ros, E. Alarcón, M. Solé, V. Muntés-Mulero, D. Meyer, S. Barkai, M. J. Hibbett, G. Estrada, K. Ma'arif, F. Coras, V. Ermagan, H. Latapie, C. Cassar, J. Evans, F. Maino, J. Walrand y A. Cabellos, "Knowledge-Defined Networking," *SIGCOMM Comput. Commun. Rev.*, vol. 47, n.º 3, 2-10, sep. de 2017.
- [30] T. T. T. Nguyen y G. Armitage, "A survey of techniques for internet traffic classification using machine learning," *IEEE Communications Surveys Tutorials*, vol. 10, n.º 4, págs. 56-76, 2008.
- [31] P. Bermolen y D. Rossi, "Support vector regression for link load prediction," en *2008 4th International Telecommunication Networking Workshop on QoS in Multiservice IP Networks*, 2008, págs. 268-273.
- [32] A. Lakhina, M. Crovella y C. Diot, "Mining anomalies using traffic feature distributions," en *In ACM SIGCOMM*, 2005, págs. 217-228.
- [33] J. Zhang, Y. Xiang, W. Zhou y Y. Wang, "Unsupervised traffic classification using flow statistical properties and IP packet payload," *Journal of Computer and System Sciences*, vol. 79, n.º 5, págs. 573-585, 2013.
- [34] W. Iqbal, M. N. Dailey y D. Carrera, "Unsupervised Learning of Dynamic Resource Provisioning Policies for Cloud-Hosted Multitier Web Applications," *IEEE Systems Journal*, vol. 10, n.º 4, págs. 1435-1446, 2016.
- [35] J. Hyun, N. V. Tu y J. Hong, "Knowledge-defined networking using in-band network telemetry," *2017 19th Asia-Pacific Network Operations and Management Symposium (APNOMS)*, págs. 54-57, 2017.
- [36] T. En-Najjary, "Traffic classification : Application-based feature selection using logistic regression," 2010.
- [37] S. Santiago Lopes Pereira, J. L. De Castro e Silva y J. E. Bessa Maia, "NTCS: A real time flow-based network traffic classification system," en *10th International Conference on Network and Service Management (CNSM) and Workshop*, 2014, págs. 368-371.
- [38] A. Pradhan, "Network Traffic Classification using Support Vector Machine and Artificial Neural Network," oct. de 2011.
- [39] M. Reza, M. J. Sobouti, S. Raouf y R. Javidan, "Network Traffic Classification using Machine Learning Techniques over Software Defined Networks," *International Journal of Advanced Computer Science and Applications*, vol. 8, ene. de 2017.
- [40] R. Nossenson y S. Polacheck, "On-Line Flows Classification of Video Streaming Applications," en *2015 IEEE 14th International Symposium on Network Computing and Applications*, 2015, págs. 251-258.
- [41] O. Project, "OpenDaylight Controller," [Online]. Available: <https://www.opendaylight.org/>.
- [42] L. Castañeda, "Datavideo, Código para la comparación de rendimiento de diferentes modelos de ML para video streaming," (2020, Nov), [Online]. Available: <https://github.com/luisingeniero11/datavideo>.



Luis Miguel Castañeda Herrera. candidato a Magíster en Ingeniería, Área de Telecomunicaciones e Ingeniero en Electrónica de la Universidad del Quindío, Colombia. Sus líneas de investigación son: Redes definidas por software, Radio definida por software y Redes 5G.



Alejandra Duque-Torres recibió el título de ingeniera electrónica por la Universidad del Quindío, Colombia, en 2017. Durante sus estudios, realizó una pasantía en el Centro De Investigaciones En Óptica A.C., Leon de Guanajuato, México. En el 2019, recibió el título de magíster en ingeniería telemática por la Universidad del Cauca, Colombia. Durante sus estudios de maestría, fue visitante académico en *School of Engineering and Computer Science, Victoria University of Wellington*, Nueva Zelanda. Actualmente, es investigadora junior y estudiante de doctorado en el *Institute of Computer Science* en *University of Tartu*, Estonia. Sus intereses de investigación incluyen la gestión de redes y servicios, redes definidas por software, ingeniería de software, aprendizaje automático y el análisis de grandes cantidades de datos (Big Data).



Wilmar Yesid Campo Muñoz. Ph.D en Ingeniería Telemática, Magíster en Ingeniería, Área Telemática e Ingeniero en Electrónica y Telecomunicaciones de la Universidad del Cauca, Colombia. Miembro del grupo de investigación GITUQ y profesor asociado de la Universidad del Quindío, Colombia. Sus líneas de investigación son: Redes definidas por software, Redes 5G y Teletráfico.