

Estimación de KQIs de video streaming en entornos Wi-Fi

Manuel Bautista Martínez⁽¹⁾, José Pulido⁽¹⁾, Sergio Fortes⁽¹⁾, Carlos Baena⁽¹⁾, Oswaldo Sebastián Peñaherrera-Pulla⁽¹⁾
Alfonso Fernández-Durán⁽²⁾, Raquel Barco⁽¹⁾

⁽¹⁾Telecommunication Research Institute (TELMA), Universidad de Málaga E.T.S. Ingeniería de Telecomunicación, Bulevar Louis Pasteur 35, 29010 Málaga (Spain)

{mbmarrod, josepa, sfr, jcbg, sppulla, rbm}@ic.uma.es

⁽²⁾Nokia Spain, María Tubau 9, 28050 Madrid, Spain
alfonso.fernandez_duran@nokia.com

Resumen—The progress in wireless technologies and the growing demand of society to stay permanently connected have elevated the importance of wireless communications to the point where they have become an essential aspect of daily life. Furthermore, the most significant impact on network traffic growth is attributed to the emergence of video streaming services. Hence, the objective of this study is to investigate the impact that Wi-Fi network conditions have on video streaming user experience quality (QoE). To do so, the present article presents a system based on Machine Learning classification and regression models for the estimation of Video Streaming Key Quality Indicators (KQIs) based on network low-layer configuration and metrics.

I. INTRODUCCIÓN

El progreso en las tecnologías inalámbricas y la creciente demanda de la sociedad de mantenerse permanentemente conectada han elevado la importancia de las comunicaciones inalámbricas hasta convertirlas en un aspecto esencial de la vida cotidiana. Los avances y la extensa implementación de redes locales inalámbricas (WLAN) y herramientas de compresión de video de última generación [1] permiten la emergencia de aplicaciones de transmisión multimedia en diversos entornos como hogares, campus universitarios, espacios de trabajo colaborativo y empresas [2].

El mayor impacto en el crecimiento del tráfico de red se atribuye a la aparición de servicios de transmisión de video *Over-the-Top* (OTT). El video bajo demanda ha motivado una revolución completa de los paradigmas y características de los contenidos multimedia de alta calidad y un drástico cambio en los patrones de consumo de los usuarios finales. Esta tendencia, combinado con la accesibilidad, costo reducido y soporte multimedia del estándar IEEE 802.11, ha impulsado la predominancia de las redes Wi-Fi en el mercado y ha planteado nuevos desafíos en términos de rendimiento de la red y experiencia del usuario [3].

Estas plataformas de streaming de video como Twitch, Netflix o YouTube emplean el protocolo de video adaptativo sobre HTTP, más conocido como DASH (*Dynamic Adaptive Streaming over HTTP*). Este protocolo está diseñado para respaldar un modelo de transmisión de medios en el que el control recae principalmente en el cliente [4].

El video se codifica en diferentes niveles de calidad y se fragmenta en segmentos de igual duración que se almacenan en un servidor de medios basado en HTTP. Los usuarios solicitan periódicamente distintos segmentos de video, de una

u otra calidad según las condiciones estimadas de la red para garantizar una transmisión sin interrupciones.

No obstante, estos servicios pueden tener un impacto significativo en el rendimiento, la latencia y la fluctuación en la calidad percibida por los usuarios si no se gestionan de forma eficiente. Una selección inapropiada del bitrate asociado a las calidades puede provocar que los clientes sufran una transmisión de video inestable, como el desbordamiento del búfer y una disminución en la calidad de video.

En años anteriores, estas redes se optimizaban en base a indicadores de rendimiento (*Key Performance Indicators*, KPIs), los cuales se refieren a las capas más bajas de la torre de protocolos. De esta forma, se pretendía hacer una aproximación de la calidad de experiencia (*Quality of Experience*, QoE) percibida por el usuario. Sin embargo, el nuevo paradigma permite conocer con más detalle la QoE *end-to-end* (E2E) óptima en base a definición y análisis de indicadores de calidad (*Key Quality Indicators*, KQIs). Tradicionalmente, los Proveedores de Servicios de Internet (*Internet Service Providers*, ISPs) empleaban la Inspección Profunda de Paquetes (DPI - Deep Packet Inspection) para obtener información sobre los niveles de calidad de video. Sin embargo, por cuestiones de seguridad y privacidad, hoy en día la mayor parte de las plataformas de streaming utilizan transmisiones encriptadas (HTTPS) [5][6].

Como consecuencia, surge la necesidad de la monitorización del tráfico a nivel de red para la estimación de la calidad del video, es decir, establecer un modelado de KQIs en base a parámetros de configuración de red y KPIs que nos permite la gestión de la red orientada a la experiencia E2E [7]. Varios estudios recientes han encontrado una solución en las técnicas de aprendizaje automático (*Machine Learning*, ML) para encontrar dicha relación[8][9].

En este marco, el presente trabajo describe la implementación de un sistema de estimación de KQIs referentes a video streaming basado en los parámetros de configuración de una red Wi-Fi, basada en el estándar IEEE802.11n, y sus KPIs más relevantes. De esta forma, el trabajo se estructura de la siguiente manera: En la sección II se describe el diseño e implementación del sistema propuesto para la estimación de KQIs de video streaming entrando en profundidad en cada uno de los elementos que lo componen. A continuación, en la sección III se exponen los resultados obtenidos como resultado de un conjunto de pruebas utilizando el sistema

desarrollado, se evalúan las diferentes técnicas de estimación empleadas y se discute su precisión en la predicción de parámetros en una red Wi-Fi. Finalmente, en la sección IV se presentan las conclusiones y el trabajo futuro en esta línea.

II. SISTEMA DE ESTIMACIÓN

En esta sección se presenta el sistema propuesto para la predicción de KQIs a partir de KPIs y parámetros de configuración Wi-Fi para el servicio de video streaming DASH.

En la Figura 1 se muestra la arquitectura del sistema de estimación propuesto.

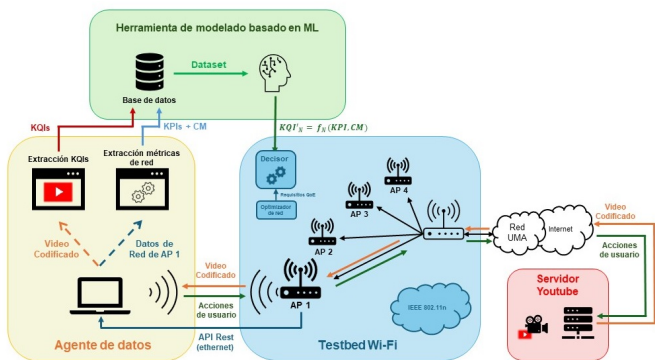


Fig. 1. Arquitectura del sistema de estimación propuesto.

A. Sistema de obtención de datos

Este bloque es el primer paso para la construcción del dataset de los datos. Está basado en la creación de un banco de pruebas en las cuales se realizan múltiples ejecuciones de visualización de un video adaptativo disponible en todas las resoluciones hasta 4K y de 3 minutos de duración.

Durante la ejecución de cada experimento se hace uso de un cliente de video que recoge las medidas de los diferentes KQIs correspondientes a video streaming así como KPIs de la red obtenidos cada segundo. Para enriquecer la base de datos de entrenamiento que se emplea en el modelado posterior, se ejecutan pruebas en múltiples escenarios.

Este bloque se compone fundamentalmente por el agente de datos, el testbed Wi-Fi y el servidor de Youtube.

En primer lugar, el servidor de YouTube. Una de las plataformas más populares que ofrecen contenido VOD y LS (*Live Streaming*). En el caso de YouTube, la plataforma utiliza los protocolos DASH y HLS para ofrecer VOD y LS respectivamente, lo que permite la reproducción de contenido en resolución 4K.

Por otro lado, la infraestructura de red Wi-Fi responsable de proporcionar la conexión Wi-Fi al cliente. Basándose en sus especificaciones, el banco de pruebas está basado en el estándar IEEE802.11n y se compone principalmente por varios puntos de acceso, un controlador central y el conjunto de dispositivos clientes. Los puntos de acceso permiten la conectividad Wi-Fi a través de la red de la Universidad de Málaga (UMA) con acceso a través de Internet y se encuentran equipados con una Interfaz de Programación de Aplicaciones (API) que facilita la extracción de métricas de red de los dispositivos.

Finalmente, el agente de datos se compone de un cliente DASH y la herramienta KQI Dash video [10]. Herramienta

que permite la monitorización en tiempo real y la obtención de los KQIs definidos para video. La herramienta se basa en una serie de scripts de Python que basan sus acciones en el framework software Selenium [11], que proporciona una API que permite simular las acciones requeridas por el usuario para inicializar la reproducción de un video y la extracción de métricas del reproductor relacionados con el rendimiento del video, como por ejemplo la resolución mostrada por pantalla durante la reproducción. Por otro lado, en segundo plano se ejecuta un script de Python encargado de monitorizar la recogida de datos referente a los distintos KPIs y parámetros de configuración de la red (CMs) en cada momento. Esta herramienta se basa en la automatización del envío de peticiones HTTP para solicitar las métricas de la red empleando el framework instalado en el punto de acceso al que el cliente DASH se encuentra conectado del banco de pruebas citado anteriormente.

B. Estimación de KQIs

Una vez se preparan correctamente los datos obtenidos del sistema anterior se dispone de un dataset sobre el que trabajar. Para la creación de los modelos se ha determinado que los parámetros de entrada utilizados sean los KPIs: throughput y el indicador de nivel de la señal total recibida incluyendo interferencias (*Received Singal Stregth Indicator*, RSSI) medidos de la red y obtenidos con una resolución de un segundo. Mediante diferentes algoritmos de ML se genera un modelo de estimación para cada uno de los distintos KQIs del servicio de video. Los KQIs que se pretenden estimar a través de diferentes modelos de ML son:

- **Reach 1080p, 2K y 4K**: se alcanzan o no las resoluciones 1080p, 2K o 4K durante la reproducción del video.
- **Time to Reach 1080p, 2K y 4K**: el tiempo en segundos que se tarda en alcanzar dicha resolución.
- **Percentage of 1080p, 2K y 4K**: el porcentaje de 1080p, 2K y 4K estimado de la sesión de video.

C. QoE basada en KQIs estimados

Una vez finalizado el análisis de las métricas de evaluación de los distintos modelos entrenados, se dispone del mejor modelo de estimación para cada KQI. Estos modelos se emplean para estimar periódicamente la calidad de experiencia mientras la red se encuentra en funcionamiento. De este modo se conoce la calidad que el punto de acceso brinda al cliente a nivel de aplicación y, en concreto, para un servicio de video streaming de alta calidad.

III. EVALUACIÓN

La evaluación del sistema depende de dos bloques fundamentales. Por un lado, se realizará un análisis profundo del dataset obtenido del sistema de obtención de datos de la sección II el cual se va a emplear para entrenar los modelos. Por otro lado, una vez obtenidos los modelos se realizará un detenido estudio de las métricas de evaluación y la precisión de los diferentes modelos correspondientes a cada KQI.

A. Conformación del dataset

El primer paso en la cadena del ML es la automatización del banco de pruebas para la obtención de un dataset que intente describir la situación de la mejor manera posible. Para

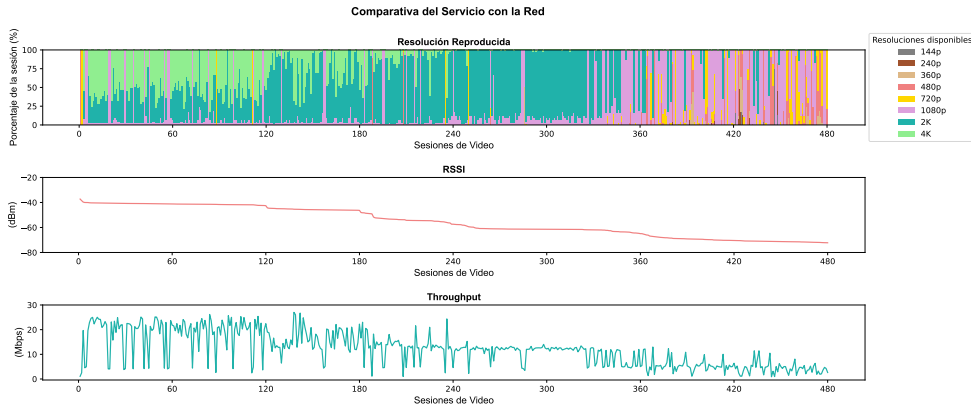


Fig. 2. Representación del porcentaje de visualización de cada resolución en comparación con el RSSI y el throughput en cada experimento.

ello se definen las condiciones de los experimentos en los diferentes contextos planteados. El conjunto de experimentos está formado por 480 experimentos de 3 minutos de duración con la configuración fija del punto de acceso en el canal 1, ancho de banda 20MHz y potencia de transmisión 20dBm ejecutados en diferentes condiciones de distancia (1, 5, 10 y 20 metros) e interferencia (escenario no congestionado y congestionado) para plantear diferentes escenarios que permitan la variabilidad del throughput y el RSSI. Cada experimento contiene 180 muestras referentes a los 180 segundos de vídeo que son resumidas en un único valor por experimento que es la mediana o la media del conjunto de muestras recogidas. De modo que finalmente el dataset queda como un conjunto de 480 valores por cada parámetro de entrada y por cada KQI de salida.

Por un lado, en la Figura 2 se representan los porcentajes de las calidades visualizadas durante cada sesión teniendo en cuenta distintas distancias y situaciones de interferencia para variar el RSSI y el throughput de entrada. Analizando el conjunto de pruebas, se puede observar que la disminución del RSSI en los distintos escenarios planteados mantiene relación con la disminución del throughput y consecuentemente disminuye el alcance del HD (*High-Definition*), eleva el tiempo para alcanzarlo y disminuyen los porcentajes de 2K y 4K durante la sesión. La disminución de la potencia reduce la transmisión de bits por segundo. Por tanto, el cliente DASH va a solicitar una calidad inferior con tal de mantener el relleno del buffer y la reproducción ininterrumpida del vídeo. Cuando la distancia es de 1 metro (sesiones 1-120) el cliente alcanza

4K sin dificultad una vez se ha realizado la descarga inicial de datos. Cuando la distancia es de 5 metros (sesiones 121-240) obtenemos cada vez un porcentaje mayor de 2K frente a 4K durante la reproducción a medida que el escenario está más congestionado. A 10 metros de distancia (sesiones 241-360), ya no se alcanza el 4K y también empieza a aparecer más de una sesión en 720p. Finalmente, con una distancia de 20 metros (sesiones 361-480) la señal se degrada y las calidades reproducidas que dominan durante las sesiones son 1080p y 720p.

B. Modelos de estimación

La casuística que se plantea corresponde por un lado a un caso de clasificación para la estimación de *Reach 1080p*, *2K* y *4K*, y por otro lado, a un caso de regresión para los KQIs *Time to Reach 1080p*, *2K* y *4K* y *Percentage of 1080p*, *2K* y *4K*. En el caso de clasificación, los modelos se crean a partir de la evaluación de 6 técnicas diferentes de clasificación: *Random Forest* (RF), *Ridge* (RC), *Neural Networks* (NN), *K-nearest Neighbors* (KNN), *Support Vector Machine* (SVC) y *Gaussian Naive Bayes* (GNB). En el caso de regresión: RF, RR, NN, KNN, SVR y *Adaptive Boosting* (ABR).

Se han empleado numerosas métricas de evaluación para poder determinar cuál es el modelo que mejor se ajusta. En cuanto a la clasificación, en la Figura 3 por ejemplo se representan los valores de F1-score de cada uno de los modelos citados para ver si se alcanza 1080p. Al tratarse de un parámetro que tiene en cuenta tanto *precision* como *recall*, se ha empleado para determinar la certeza con la que cada modelo se ajusta a los datos. En la figura mostrada, la línea roja discontinua indica que RF obtiene el mejor valor con F1-score igual a 0.99. La configuración óptima de hiperparámetros a la que responde es *Máxima profundidad del modelo: 5* y *Número mínimo de muestras necesarias para estar en un nodo hoja: 10*.

Por otro lado, para la regresión, por ejemplo en la Figura 4 se representa el error medio absoluto (*Mean Absolute Error*, MAE) en comparación con el promedio de los valores pasados de cada modelo para los porcentajes de 4K durante la sesión. Este coeficiente se ha empleado para valorar cómo de bien estima cada modelo con respecto a la media de los valores. Nuevamente, RF obtiene el mejor valor con un 12% de error sobre la media. La configuración óptima de hiperparámetros

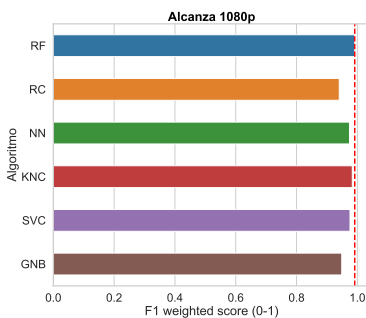


Fig. 3. F1-Score de las diferentes técnicas de clasificación evaluadas para *Reach 1080p*.

a la que responde es *Máxima profundidad del modelo: 7* y *Número de árboles en el bosque: 100*.

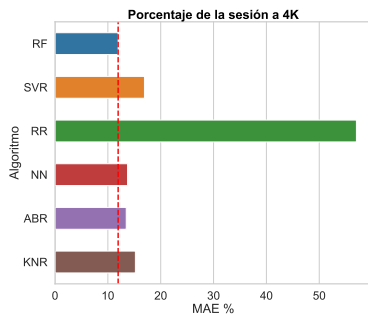


Fig. 4. MAE sobre la media de valores pasados de las diferentes técnicas de regresión evaluadas para el porcentaje de 4K en una sesión.

En las Figuras 5 y 6 se observan la predicción de porcentaje de la sesión 4K y cuanto tiempo tarda en alcanzarlo empleando Random Forest.

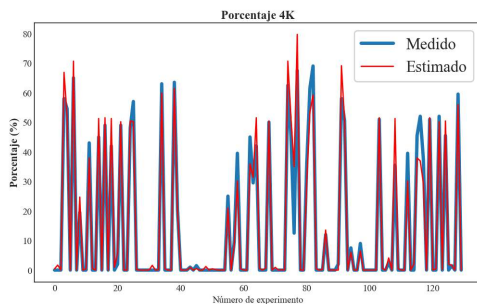


Fig. 5. Estimación de Porcentaje 4K con RF.

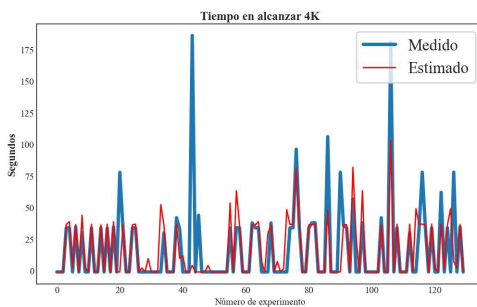


Fig. 6. Estimación de Time to 4K con RF.

IV. CONCLUSIONES Y TRABAJO FUTURO

En este artículo se ha presentado el desarrollo de un sistema de predicción de KQIS a partir de KPIs y parámetros de configuración de una red Wi-Fi real. El trabajo desarrollado se centra únicamente en el servicio de video streaming, que ha sido implementado en un entorno cliente-servidor DASH. Se ha desarrollado una herramienta para la monitorización de los KQIs y KPIs medidos tanto en el reproductor de vídeo como en la red de pruebas Wi-Fi de forma sincronizada. Los KQIs que se estiman están relacionados con las calidades ofrecidas al usuario, como por ejemplo si se alcanza HD, cuanto tiempo ha de pasar y qué porcentaje cubre de la sesión.

Este trabajo ha permitido realizar un sondeo de los diferentes escenarios que se dan en una red Wi-Fi y el impacto

que tienen las condiciones de la red en la calidad de experiencia del usuario. A partir de un exhaustivo estudio de los resultados obtenidos en los experimentos realizados, se han creado numerosos modelos de clasificación y regresión capaces de estimar la calidad de experiencia que esperaría el cliente en caso de disfrutar de un servicio de video bajo demanda. En cuanto al trabajo futuro, el sistema desarrollado en este trabajo, pretende ser objeto de uso de un gestor de red orientado a la optimización para mejorar la calidad de experiencia E2E en entornos Wi-Fi.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el Centro para el Desarrollo Tecnológico Industrial (CDTI) del Ministerio de Ciencia e Innovación en el marco del proyecto MELODIC (Ref. IDI-20220551), el Ministerio de Educación bajo la Beca de colaboración con departamentos y la Universidad de Málaga a través del II Plan Propio de Investigación, Transferencia y Divulgación Científica, la Junta de Andalucía a través de la Secretaría General de Universidades, Investigación y Tecnología con beca predoctoral (Ref. PREDOC 01712) y el Ministerio de Ciencia e Innovación (subvención FPU19/04468) y el Ministerio de Asuntos Económicos y Transformación Digital y la Unión Europea - NextGenerationEU, en el marco del Plan de Recuperación, Transformación y Resiliencia y el Mecanismo de Recuperación y Resiliencia bajo el proyecto MAORI.

REFERENCIAS

- [1] S. Pérez, H. Facchini, A. Dantiacq, G. Q. Salomn, G. Cangemi, and F. Hidalgo, "Comparison of the Behavior of Video Codescs in Wi-Fi IEEE 802.11ac Environment," in *2020 IEEE Congreso Biental de Argentina (ARGENCON)*, 2020, pp. 1–8.
- [2] A. Moid and A. O. Fapojuwo, "Test-bed implementation of a cross-layer framework for video streaming over IEEE 802.11 ad-hoc wireless network," in *2009 IEEE 20th International Symposium on Personal, Indoor and Mobile Radio Communications*, 2009, pp. 2965–2969.
- [3] E. Coronado, J. Villalón, and A. Garrido, "Improvements to Multimedia Content Delivery over IEEE 802.11 Networks," in *NOMS 2020 - 2020 IEEE/IFIP Network Operations and Management Symposium*, 2020, pp. 1–6.
- [4] "International organization for standarization and international electrotechnical commission, Information technology Dynamic adaptive streaming over HTTP (DASH) Part 1: Media presentation description and segment formats." ISO/IEC 23009-1, 2022.
- [5] I. Oršolić, P. Rebernjak, M. Sužnjević, and L. Skorin-Kapov, "In-Network QoE and KPI Monitoring of Mobile YouTube Traffic: Insights for Encrypted iOS Flows," in *2018 14th International Conference on Network and Service Management (CNSM)*, 2018, pp. 233–239.
- [6] S. Göring, A. Raake, and B. Feiten, "A framework for QoE analysis of encrypted video streams," in *2017 Ninth International Conference on Quality of Multimedia Experience (QoMEX)*, 2017, pp. 1–3.
- [7] C. Baena, S. Fortes, E. Baena, and R. Barco, "Estimation of Video Streaming KQIs for Radio Access Negotiation in Network Slicing Scenarios," *IEEE Communications Letters*, vol. 24, no. 6, pp. 1304–1307, 2020.
- [8] I. Orsollic, M. Suznjevic, and L. Skorin-Kapov, "YouTube QoE Estimation from Encrypted Traffic: Comparison of Test Methodologies and Machine Learning Based Models," in *2018 Tenth International Conference on Quality of Multimedia Experience (QoMEX)*, 2018, pp. 1–6.
- [9] A. Pimpinella, A. E. C. Redondi, F. Loh, and M. Seufert, "Machine-Learning Based Prediction of Next HTTP Request Arrival Time in Adaptive Video Streaming," in *2021 17th International Conference on Network and Service Management (CNSM)*, 2021, pp. 558–564.
- [10] C. Baena, O. S. Peñaherrera-Pulla, L. Camacho, R. Barco, and S. Fortes, "Video Streaming and Cloud Gaming Services Over 4G and 5G: A Complete Network and Service Metrics Dataset," *IEEE Communications Magazine*, vol. 61, no. 9, pp. 154–160, 2023.
- [11] "Selenium - Web Browser Automation," <https://www.selenium.dev/>, (acceso Diciembre 2023).