

Universidad Autónoma de Baja California

Facultad de Ingeniería, Arquitectura y Diseño



Programa de Maestría y Doctorado en Ciencia e Ingeniería

Título de la tesis:

**“SISTEMA CLASIFICADOR DE SERVICIOS 5G/B5G SOPORTADO POR
TÉCNICAS DE MACHINE LEARNING”**

Tesis presentada por:

JORGE ENRIQUE PRECIADO VELASCO

para obtener el grado de DOCTOR EN CIENCIAS

Dirigida por: **Dr. Juan Iván Nieto Hipólito**

Codirigida por: **Dr. Raúl Rivera Rodríguez**

Ensenada, Baja California, septiembre del 2021.

Universidad Autónoma de Baja California

Facultad de ingeniería, Arquitectura y Diseño

Programa de Maestría y Doctorado en Ciencias e Ingeniería

“SISTEMA CLASIFICADOR DE SERVICIOS 5G/B5G SOPORTADO
POR TÉCNICAS DE MACHINE LEARNING”

Tesis presentada por:

Jorge Enrique Preciado Velasco

para obtener el grado de DOCTOR EN CIENCIAS

Aprobada por:



Dr. Juan Iván Nieto Hipólito

Director de Tesis



Dr. Raúl Rivera Rodríguez

Co-director de Tesis



Dr. José Ángel González Fraga

Miembro del Comité



Dr. Juan de Dios Sánchez López

Miembro del Comité



Dr. Jesús Everardo Olguín Tizado

Miembro del Comité

Ensenada, Baja California, septiembre 2021

RESUMEN

Resumen de la tesis de Jorge Enrique Preciado, “Sistema clasificador de servicios 5G/B5G soportado por técnicas de Machine Learning”

La última generación de redes inalámbricas móviles que se está implantando en el mundo se conoce como red 5G. Esta red de comunicaciones está pensada como una red centrada en proporcionar servicios no solo a humanos sino a atender las necesidades de los mercados verticales. Los proveedores de servicios de infraestructura de comunicaciones se enfrentan a lo que quizá sea el mayor reto de su existencia en el despliegue de redes 5G: el desafío de ofrecer simultáneamente servicios con la mejor Calidad de Servicio (QoS) así como atender a los usuarios para que experimenten una mejor Calidad de Experiencia (QoE). Las características de desempeño (KPI) y de calidad (KQI) de los servicios hacen que su comportamiento incida en el desempeño de las redes por lo que se necesita identificarlos plenamente. La clasificación de servicios en redes 5G / B5G (*Beyond 5G*) toma relevancia para los proveedores de servicios de telecomunicaciones ya que les permite seleccionar con precisión los segmentos de red asignando los recursos necesarios para cada servicio, mejorando así la QoS de la red y la QoE percibida por los usuarios, y asegurando el cumplimiento del Acuerdo de nivel de servicio (SLA).

Algunos proyectos han desarrollado sistemas para clasificar estos servicios basados en los indicadores KPI que caracterizan los diferentes servicios. Sin embargo, aunque los indicadores clave de calidad (KQI) también son importantes en las redes 5G y generalmente no los consideran. En este trabajo, se propone un clasificador de servicios que utiliza un enfoque de aprendizaje automático (ML) basado en el aprendizaje supervisado (SL), para mejorar la clasificación y respaldar así una mejor distribución de recursos y tráfico a través de redes basadas en 5G/B5G. Una de las premisas más importante, es considerar la inclusión de los KQI (adicionalmente a los KPI) y demostrar a través de simulaciones, que el esquema propuesto logra una mejor predicción con un clasificador *Random Forest*, con una precisión del 97% y un coeficiente de correlación de Matthews del 96,6%. Se prevé que la clasificación de servicios continuará como tema relevante en la investigación de requerimientos, casos de uso y capacidades de redes futuras (2030 y posteriores).

Aprobado por:



Dr. Juan Iván Nieto Hipólito

Director de Tesis



Dr. Raúl Rivera Rodríguez

Co-director de Tesis

ABSTRACT

The latest generation of mobile wireless networks implemented in the world is known as the 5G network. This communications network designed as a network focused on providing services to humans and meeting the needs of vertical markets. Communications infrastructure service providers face the greatest challenge of their existence in the deployment of 5G networks: the challenge of simultaneously offering services with the best Quality of Service (QoS) and serving users to experience a better quality of service Experience (QoE). The performance (KPI) and quality (KQI) parameters of the services affect their performance behavior of the networks, so it is necessary to identify them entirely. Therefore, the classification of services in 5G/B5G (Beyond 5G) networks becomes relevant for telecommunications service providers. Besides, the classification allows them to select the network segments allocating the necessary resources for each service, thus, improving the network's QoS and QoE perceived by users and ensuring compliance with the Service Level Agreement (SLA).

Some projects have developed systems to classify these services based on the KPIs that characterize the different services. However, although the quality indicators (KQIs) are also crucial in 5G networks, they are commonly not considered. We propose a service classifier that uses a machine learning (ML) approach based on supervised learning (SL) to improve classification and thus support the better distribution of resources and traffic over 5G-based networks. Considering the KQI inclusion (additionally to the KPI) is one of the most critical premises. We demonstrate through simulations that the proposed scheme achieves a better prediction with a Random Forest classifier, getting a precision of 97% and a Matthews correlation coefficient of 96.6%. The classification of services will continue as a relevant topic in investigating requirements, use cases, and capacities of future networks (2030 and later).

Palabras Clave: Gestión de servicios y redes 5G/B5G, modelos predictivos, Machine Learning, clasificación de servicios, KPI, KQI, QoS, QoE, SLA.

ÍNDICE

RESUMEN	i
ABSTRACT	ii
ÍNDICE DE TABLAS	vii
ÍNDICE DE FIGURAS	ix
SIGLARIO DE TÉRMINOS	xiii
1 PRESENTACIÓN	1
1.1 Introducción	1
1.2 Justificación	2
1.3 Descripción del problema	4
1.4 Pregunta e hipótesis de investigación.	6
1.5 Objetivo General	7
1.6 Objetivos específicos	7
1.7 Secuencia de la tesis	8
2 CAPÍTULO: LAS REDES 5G, SUS CARACTERÍSTICAS, SERVICIOS Y LA GESTIÓN DE SU DESEMPEÑO.	10
2.1 Introducción	10
2.2 Generalidades y gestión de la red 5G, trabajos relacionados.	11
2.2.1 Servicios sobre redes 5G	15
2.2.2 Indicadores o parámetros claves de desempeño (KPI) y de calidad (KQI)	24

2.2.2.1	Indicadores claves de desempeño (KPI)	25
2.2.2.2	Indicadores claves de calidad (KQI)	27
2.2.3	Base de datos (<i>dataset</i>) de valores de los indicadores claves de desempeño y de calidad.	30
2.2.4	Contratos o acuerdos a nivel de servicio (SLA)	31
2.3	Evolución a una arquitectura basada en servicios (SBA) en 5G	33
2.4	Segmentación de red (NS, <i>Network Slicing</i>)	38
2.5	Clasificación de servicios 5G, estado del arte	42
2.6	Aprendizaje automatizado, <i>Machine Learning</i> (ML)	45
2.6.1	Esquema general de ML	47
2.6.2	Validación cruzada	48
2.6.3	Aprendizaje supervisado, no supervisado y reforzado	49
2.6.4	Aprendizaje no supervisado	52
2.6.5	Aprendizaje reforzado	53
2.7	Aplicación de ML a la gestión de redes 5G	56
2.8	Conclusiones	59
3	CAPÍTULO: PROPUESTA DE UN SISTEMA DE CLASIFICACIÓN DE SERVICIOS	61
3.1	Introducción	61
3.2	Propuesta del sistema para clasificar servicios, su esquema general.	62
3.3	Construcción de la base de datos (<i>dataset</i>) de los servicios	63
3.4	Propuesta de modelo predictivo y algoritmos de ML para la clasificación de servicios	65
3.4.1	Descripción del diagrama del modelo predictivo	66

3.4.1.1	Etiquetado de los datos	66
3.4.1.2	División de los datos para entrenamiento y prueba	67
3.4.1.3	Entrenamiento del algoritmo de ML.	68
3.4.1.4	Validación del algoritmo de ML y prueba del modelo predictivo	69
3.4.2	Validación del modelo predictivo y sistema clasificador.	70
3.4.2.1	Matriz de confusión y métricas de desempeño.	70
3.5	Servicios clasificados y su incidencia en la gestión de desempeño.	74
3.6	Recomendaciones para implementar el sistema de clasificación de servicios 5G que se propone	76
3.7	Conclusiones	79
4	CAPÍTULO: VALIDACIÓN DEL SISTEMA PROPUESTO	81
4.1	Introducción	81
4.2	Escenario de validación	81
4.2.1	Selección del algoritmo de ML	82
4.2.2	Selección del lenguaje de programación y de la plataforma de desarrollo	82
4.2.3	Servicios 5G a clasificar y sus parámetros KPI y KQI	84
4.2.4	<i>Dataset</i> de parámetros claves de los servicios.	86
4.3	Validación o comprobación del sistema de clasificación propuesto.	87
4.3.1	CASO 1: Simulación usando solo KPI	88
4.3.1.1	Etiquetado de los datos	88
4.3.1.2	División de datos	88
4.3.1.3	Entrenamiento del algoritmo de ML	89

4.3.1.4	Validación del algoritmo ML y prueba del modelo predictivo	90
4.3.1.5	Validación del modelo predictivo	91
4.4	CASO 2: Simulación con la incorporación de los KQI	96
4.5	Valoración de los resultados	106
4.6	Conclusiones del capítulo	108
5	CONCLUSIONES	109
6	RECOMENDACIONES y TRABAJO FUTURO	112
7	REFERENCIAS BIBLIOGRÁFICAS	114
3	ANEXO 1. Parámetros de KPI y KQI de servicios 5G	123
4	ANEXO 2. Base de datos (<i>dataset</i>) creada con valores KPI y KQI de los servicios 5G	126
5	ANEXO 3. Tipos de datos de los parámetros de KPI y KQI de los servicios 5G	135
6	ANEXO 4. Función para crear el Bosque Aleatorio	136

ÍNDICE DE TABLAS

Tabla 1 Fragmento de la base de datos construida	65
Tabla 2 Ejemplo de matriz de confusión para clasificación binaria	71
Tabla 3. Análisis de las características de algunos algoritmos de SL de ML [10].	77
Tabla 4. Comparativa de algunas plataformas de desarrollo de código abierto [Elaboración propia], [69][70].	84
Tabla 5. Resultados de la precisión en la etapa de validación cruzada para la primera simulación (KPI).	90
Tabla 6. Resultados del modelo árbol de decisión (1ra simulación KPI). Nota: Support indica cantidad.	93
Tabla 7. Resultados del modelo bosque aleatorio (1ra simulación KPI)	93
Tabla 8. Resultados del modelo SVM (1ra simulación KPI).	94
Tabla 9. Resultados del modelo KNN (1ra simulación KPI).	95
Tabla 10. Resultados del modelo de MLPC (1ra simulación KPI).	95
Tabla 11. Métricas resultado del modelo para la primera simulación (KPI)	96
Tabla 12. Resultados de la precisión en la etapa de validación cruzada para la segunda simulación (KPI+KQI).	98
Tabla 13. Resultados del modelo árbol de decisión (2da simulación KPI + KQI).	99
Tabla 14. Resultados del modelo de bosque aleatorio (2da simulación).	100
Tabla 15. Resultados del modelo de SVM (2da simulación).	100
Tabla 16. Resultados del modelo KNN (2da simulación).	101

Tabla 17. Resultados del modelo MLPC (2da simulación).	101
Tabla 18. Métricas resultado del modelo para la segunda simulación (KPI+KQI)	102
Tabla 19. Promedios de las métricas de evaluación en ambos casos de simulación [Elaboración propia].	107
Tabla 20. Parámetros de KPI para cada servicio 5G (parte uno).	123
Tabla 21. Parámetros de KPI para cada servicio 5G (parte dos).	124
Tabla 22. Parámetros de KQI de cada servicio 5G.	125
Tabla 23. Dataset de servicios 5G y sus parámetros KPI y KQI	127

ÍNDICE DE FIGURAS

Figura 1. Distribución de los servicios 5G para KPI de latencia E2E y jitter [Elaboración propia].	5
Figura 2. Visión general de 5G [1]	12
Figura 3. Ejemplos de servicios 5G y su caso de uso genéricos [1]	16
Figura 4. Importancia de algunos requerimientos claves para los casos de uso genéricos [1]	25
Figura 5. Relación de los SLA con los KPI y KQI [24].	32
Figura 6. Arquitectura básica EPS con acceso E-UTRAN [29]	34
Figura 7. Arquitectura EPS 4G [23][29][22]	35
Figura 8. Sistema de SBA de la red 5G [29][31].	37
Figura 9. Arquitectura de la red 4G [36]	41
Figura 10. Solicitud de servicios 5G a través de network slicing [36][11].	41
Figura 11. Casos de uso y la complejidad de las aplicaciones [37]	43
Figura 12. Fases del esquema general de un problema de ML [44].	47
Figura 13. Ejemplo de validación cruzada K-Folds para 5 iteraciones [46]	49
Figura 14. Modelo genérico de SL [50]	50
Figura 15. Ejemplo de un DT con tres nodos [10]	51
Figura 16. Ejemplo de un bosque aleatorio de tres DT [51]	52
Figura 17. Modelo de aprendizaje no supervisado [50]	53
Figura 18. Modelo de aprendizaje reforzado [50].	54

Figura 19. Clasificación de técnicas de Machine Learning para redes [11]	55
Figura 20. Esquema general del sistema propuesto para la clasificación de servicios 5G.	62
Figura 21. Diagrama en bloques del modelo predictivo empleando ML [Elaboración propia].	66
Figura 22. Matrices de confusión de la 1ra simulación (KPI). CV: Connected Vehicles; IE: Immersive Experience; IA: Industry Automation; SG: Smart Grid; UHD: Video Streaming; VS: Video Surveillance; VO: Vo5G; eH: e-health.	92
Figura 23. Matrices de confusión de la 2da simulación (KPI+KQI). CV: Connected Vehicles; IE: Immersive Experience; IA: Industry Automation; SG: Smart Grid; UHD: Video Streaming; VS: Video Surveillance; VO: Vo5G; eH: e-health.	98
Figura 24. Esquema de un árbol de decisión del bosque aleatorio para la primera simulación (KPI).	103
Figura 25. Esquema de un árbol de decisión del bosque aleatorio para la segunda	104
Figura 26. Comparación de los resultados obtenidos por el modelo Random Forest para ambas simulaciones.	105

Dedicatoria

A mis mujeres hermosas, Malena, Marlene, Mariely, mi tercia de M, por siempre ser el sustento que me da vida, por soportar las horas de aislamiento, les debo tanto, mi amor por siempre, las amo.

Al recuerdo de mi madre Mariana (mi póker de M), siempre presente.

A mis hermanos y mi gran familia (cuñados y yerno incluido), por su grandeza.

Agradecimientos

A mis directores Juan Iván y Raúl por darme la oportunidad de trabajar juntos, por su guía, sus consejos y amistad.

A mis sinodales, Jesús, José Ángel y Juan de Dios por su enseñanzas en clase, sus sugerencias, consejos, comentarios y enriquecimiento de la investigación.

A Cacha, mi tutora y sombra eterna, sus consejos, enseñanza y amistad.

Agradezco a tantas personas, amigos de verdad, porque en este camino siempre me han acompañado a lo largo de los años, y han aportado bastante en mi vida. intentaré en orden cronológico: A. Serrano, Victórico Rodríguez, J. Mendieta, A. Gómez, Miguel Aguayo, D. Covarrubias, R. Conte, A. Ríos, A. Sobrado, José A. Ramírez, C. Casasús, F. Muro, S. Jalife, Luis Gutiérrez, C. Rodríguez, por tantas horas conversando, conviviendo y proyectando ideas, metas, proyectos; gracias por aceptarme, aconsejarme, apoyarme, impulsarme, invitarme a colaborar y ser parte de ellos.

A mis amigos de siempre, mis hermanos de vida, gracias a Dios seguimos dando lata; mis amigos billaristas: Rodolfo C., Raúl R., Raúl T., Mario G., Saúl R., Zaid C., y Víctor A.; a los Colimotes: JuanD G., JoséL A., César V., MAAO, Saúl C., JuanM R.; los habaneros: Lavandero, Walter Baluja., Alain Garófalo., y mis Compas Tapatíos del 72: Pablo M., Rubén N., Nacho A.

A Joan D., quien en los últimos años me ha asistido en este proyecto, a la distancia, con gran profesionalismo, excelente colega, soportando mi carácter, sin su ayuda hubiera sido difícil obtener resultados interesantes, siempre ahí, trato que nos ha llevado a cultivar una amistad más allá de la distancia y de la edad.

Por último, gracias a mis ex colaboradores, de todos he aprendido. Una disculpa pues seguro omití a algunos involuntariamente, sepan que están aquí.

A la FIAD-UABC Unidad Ensenada y al CICESE por su apoyo.

SIGLARIO DE TÉRMINOS

3GPP	<i>Third Generation Partnership Project</i>	Proyecto de Asociación de 3ra Generación
3D	<i>Third Dimension</i>	Tercera dimensión
4G	<i>4th Generation Mobile Services</i>	Cuarta Generación de servicios móviles
4RI	<i>4th Industrial Revolution</i>	Cuarta revolución Industrial
5G	<i>5th Generation Mobile Services</i>	Quinta Generación de servicios móviles
6G	<i>6th Generation Mobile Services</i>	Sexta Generación de servicios móviles
5G-PPP	<i>5G Public-Private Partnership</i>	Asociación Pública-Privada de 5G
5G/B5G	<i>5G/Beyond 5G</i>	Quinta generación/ más allá de 5G
A		
AF	<i>Application Function</i>	Función de Aplicaciones
AI	<i>Artificial Intelligence</i>	Inteligencia Artificial
AMF	<i>Access & Mobility Function</i>	Función de Acceso y Movilidad
ANN	<i>Artificial Neural Networks</i>	Redes de IA
API	<i>Application Programming Interface</i>	Interfaz de Programación de aplicaciones
AR	<i>Augmented Reality</i>	Realidad Aumentada
AUSF	<i>Authentication Server Function</i>	Servidor de Funciones de Autenticación
B		
BS	<i>Base Station</i>	Estación Base
C		
CN	<i>Core Network</i>	Red de núcleo
CSV	<i>Comma Separated Values</i>	Valores separados por comas
CV	<i>Connected Vehicles</i>	Vehículos conectados
CUJAE		Ciudad Universitaria José Antonio Echeverría, Universidad Tecnológica de La Habana
D		
DL	<i>Down Link</i>	Enlace descendente
DN	<i>Data Network</i>	Red de datos
DT	<i>Decision Tree</i>	Árbol de decisión
DET-CICESE		Departamento de Electrónica y Telecomunicaciones, Centro de Investigación Científica y de educación Superior de Ensenada
DPI	<i>Deep Packet Inspection</i>	Inspección profunda de paquetes
E		
E2E	<i>End to End</i>	Extremo a Extremo
e-nodeB (e-NB)	<i>Enhanced NodeB</i>	Nodo B mejorado (nodo acceso por radio)
eMBB	<i>Enhanced Mobile Broadband</i>	Banda Ancha Móvil Mejorada
eMTC	<i>Enhanced Machine Type Communication</i>	Comunicación tipo máquina mejorada
EPC	<i>Evolved Packet Core</i>	Sistema evolucionado de paquetes en la red de núcleo
EPS	<i>Evolved Packet System</i>	Sistema evolucionado de paquetes
E-UTRAN	<i>enhanced UMTS Terrestrial Radio Access Network</i>	Red móvil Universal de acceso por radio terrestre mejorada
ETSI	<i>European Telecommunications Standard Institute</i>	Instituto Europeo de Normas de Telecomunicaciones

F		
FN		Falso Negativo
FP		Falso Positivo
FIAD-UABC		Facultad de Ingeniería Arquitectura y Diseño, Universidad Autónoma de Baja California
G		
GPRS	<i>General Packet Radio Service</i>	Servicio General de Paquetes de radio
H		
HSS	<i>Home Subscriber Server</i>	Servidor de Abonados
I		
IA	<i>Industry Automation</i>	Automatización de la Industria
IDE	<i>Integrated Development Environment</i>	Entorno de Desarrollo Integrado
IE	<i>Immerse Experience</i>	Experiencia de inmersión
IEEE	<i>Institute of Electrical and Electronics Engineers</i>	Instituto de Ingeniería Eléctrica y Electrónica
IMS	<i>Information Management System</i>	Sistema de Administración de Información
IMT	<i>International Mobile Telecommunications</i>	Telecomunicaciones Móviles Internacionales
IP	<i>Internet Protocol</i>	Protocolo de Internet
ITS	<i>Intelligence Transport Systems</i>	Sistemas de Transporte Inteligente
ITU	<i>International TelecommunicatiosUnion</i>	Unión Internacional de Telecommucatios
IoT	<i>Internets of Things</i>	Internet de las Cosas
K		
k-NN	<i>K-Nearest Neighbor</i>	k-Vecinos mas Cercanos
KPI	<i>Key Performance Indicators</i>	Indicador Clave de Desempeño
KQI	<i>Key Quality Indicators</i>	Indicador Clave de Calidad
L		
LTE	<i>Long Term Evolution</i>	Evolución a Largo Plazo
M		
MDP	<i>Markov Decision Process</i>	Proceso de Decisión Markoviana
ML	<i>Machine Learning</i>	Aprendizaje Automático
MME	<i>Mobility Management Entity</i>	Entidad de Gestión de Movilidad
mMTC	<i>Massive Machine Type Communication</i>	Comunicación Masiva Tipo Máquina
MLPC	<i>Multi-Layer Perceptron Classifier</i>	Clasificador perceptrón de Multi capas
N		
NEF	<i>Network Exposure Function</i>	Función de Exposición de Red
NFV	<i>Network Function Virtualization</i>	Virtualización de Funciones de Red
NGMN	<i>Next Generation Mobile Networks</i>	Redes Móviles de Próxima Generación
NMLRG	<i>Networks Machine Learning Research Group</i>	Grupo de Investigación de Aprendizaje Automático de Red
NR	<i>New Radio</i>	Nuevo Radio
NRF	<i>Network Repository Function</i>	Función de Repositorios de red
NS	<i>Network Slice</i>	Segmento de Red
NSSF	<i>Network Slice Selection Function</i>	Función de Selección de Segmentos de Red
Numpy	<i>Numerical Python</i>	Librería de cálculo de Python

P		
PCF	<i>Policy Control Funtion</i>	Función de Control de Políticas
PDR	<i>Peak Data Rate</i>	Tasa de datos pico
PDN	<i>Packet Data Network</i>	Red de paquetes de datos
PLR	<i>Packet Loss Ratio</i>	Razón de pérdida de paquetes
P-GW	<i>Packet data network Gateway</i>	Pasarela a la Red de paquetes de datos
Q		
QoE	<i>Quality of Experience</i>	Calidad de Experiencia
QoS	<i>Quality of Service</i>	Calidad de Servicio
R		
RAN	<i>Radio Access Network</i>	Red de Acceso de Radio
RAT	<i>Radio Access Technologies</i>	Tecnología de Acceso por Radio
S		
SBA	<i>Service Based Architecture</i>	Arquitectura Basada en Servicios
SDN	<i>Software Defined Networks</i>	Redes Definidas por Software
SG	<i>Smart Grids</i>	Red (eléctrica) Inteligente
S-GW	<i>Serving Gateway</i>	Pasarela de Servicio
SL	<i>Supervised Learning</i>	Aprendizaje Supervisado
SLA	<i>Service Level Agreement</i>	Acuerdo de Nivel de Servicio
SLO	<i>Service Level Objective</i>	Objetivo de Nivel de Servicio
SMF	<i>Session Management Function</i>	Función de Gestión de Sesión
SML	<i>Supervised Machine Learning</i>	Aprendizaje automatizado supervisado
SVM	<i>Support Vector Machine</i>	Máquina de soporte vectorial
T		
TMF	<i>Tele Management Forum</i>	Foro de Tele Gestión
U		
UDM	<i>Unified Data Management</i>	Gestión Unificada de Datos
UE	<i>User Equipment</i>	Equipo de Usuario
UHD	<i>Ultra-High Definition</i>	Ultra Alta Definición
UL	<i>Up Link</i>	Enlace Ascendente
UMTS	<i>Universal Mobile Telecommunication System</i>	Sistema de telecomunicaciones móviles universal
UPF	<i>User Plane Function</i>	Función del Plano de Usuario
urLLC	<i>Ultra-reliable Low Latency Communication</i>	Comunicación Ultra Confiable y de Baja Latencia
V		
V2I	<i>Vehicle to Infrastructure</i>	Vehículo a Infraestructura
V2N	<i>Vehicle to Network</i>	Vehículo a Red
V2P	<i>Vehicle to Pedestrian</i>	Vehículo a Peatón
V2V	<i>Vehicle to Vehicle</i>	Vehículo a Vehículo
V2X	<i>Vehicle to all</i>	Vehículo a Todo
VN		Verdadero Negativo
Vo5G	<i>Voice over 5G</i>	Voz sobre 5G
VoIP	<i>Voice over IP</i>	Voz sobre protocolo IP
VoLTE	<i>Voice over LTE</i>	Voz sobre LTE
VoNR	<i>Voice over NR</i>	Voz sobre NR (Radio Nuevo)
VP		Verdadero Positivo
VR	<i>Virtual Reality</i>	Realidad Virtual
VS	<i>Video Surveillance</i>	Vigilancia en Video

1 PRESENTACIÓN

1.1 Introducción

En los últimos años, debido sobre todo al crecimiento inusitado de necesidades de los usuarios, del desarrollo de dispositivos electrónicos, se entró en una carrera y espiral tecnológica vertiginosa. Los sistemas de comunicación móviles inalámbricos, en particular los de telefonía celular han tenido que evolucionar al mismo ritmo, las generaciones de telefonía celular muestran un ciclo de desarrollo cada 10 años.

Desde la aparición de la telefonía celular conocida como de primera generación (1G) en la década de 1980, éstas fueron siempre centrado en el cliente como ser humano, donde el servicio de voz fue el predominante y el hombre empezaba a no estar estático. Cada generación ha estado caracterizada por aspectos que van desde servicios analógicos, digitales, protocolos, arquitecturas de red, frecuencias de operación, diámetros de celdas, coberturas, número de usuarios atendidos, y un sinfín de parámetros que especifican su funcionamiento y desempeño. Así, a partir de la segunda generación (2G) se introduce la tecnología digital a velocidades de pocos kilobits por segundo donde el servicio de voz continúa en forma prioritaria; a la fecha 2021, las tecnologías de redes celulares mayormente instaladas van desde la tercera a la cuarta generación y sus variantes. Los servicios digitales se han vuelto más exigentes de recursos de red buscando proporcionar a los usuarios una mejor prestación. Si bien la voz continúa solicitada, ha sido suplantada por otros servicios como video-llamadas, realidad virtual, realidad aumentada, conexión de dispositivos como sensores y otros servicios digitales que exigen a la red, un mejor desempeño.

Las comunicaciones móviles han cambiado profundamente la vida cotidiana, y el deseo de las personas por una comunicación móvil de mayor rendimiento es continua. La red móvil

de quinta generación (5G) emerge para soportar demandas nuevas y sin precedentes más allá de la capacidad de los sistemas de generación previa. 5G viene a cambiar el paradigma, se convierte en un sistema centrado en los servicios, en proporcionar servicios digitales; servicios donde confluyen los conocidos como virtuales, los en demanda, los ubicados en la nube; situaciones como éstas, hacen que los tiempos de respuesta que exigen los usuarios de los servicios y de los proveedores y operadores de los mismos crezca.

1.2 Justificación

En reunión de la Unión Internacional de Telecomunicaciones (ITU, por sus siglas en inglés, *International Telecommunications Union*), el sector de radiocomunicaciones planteó como un gran reto de las redes inalámbricas 5G, el cumplir los requisitos de las Telecomunicaciones móviles internacionales para 2020 (IMT-2020, por las siglas del término en inglés, *International Mobile Telecommunications*) [1]. Se proyectó a 5G como una tecnología de comunicaciones habilitadora, capaz de soportar los tres casos de uso genéricos, heterogéneos y con características de tráfico diferentes que exigen requisitos estrictos y específicos de la red móvil.

Actualmente (2021), alrededor del mundo se han desplegado redes 5G, donde los operadores realizan pruebas sobre las aplicaciones existentes, de estas últimas los desarrolladores trabajan arduamente y no se tienen, aún, resultados fehacientes de que se están cumpliendo las expectativas planteadas. Diversos países de Latinoamérica realizan negociaciones con fabricantes y operadores de tecnologías 5G, así como adecuaciones a sus leyes y reglamentos para estar en condiciones tecnológicas y legales de afrontar el despliegue de este sistema de comunicaciones.

En las referencias [1], [2] y [3] se resumen algunos de los requerimientos que debe soportar la red 5G, entre los que se destaca:

- Ofrecer una experiencia de usuario consistente en una variedad de escenarios, incluidos los casos de Banda Ancha Móvil Mejorada (eMBB, por las siglas del término en inglés, *enhanced Mobile Broadband*), el cual admite conexiones estables con velocidades de datos pico muy altas; servicios de ultra-baja latencia y de alta confiabilidad (urLLC, por las siglas del término en inglés, *Ultra-reliable and Low Latency Communication*), que soportan transmisiones de paquetes de pequeñas cargas útiles a muy baja latencia y con alta confiabilidad desde un conjunto limitado de terminales; y por último, servicios de comunicación masiva tipo máquina (mMTC, por las siglas del término en inglés, *massive Machine Type Communication*), el cual admite un masivo números de dispositivos conectados que solo están esporádicamente activos y envían una pequeña carga de datos.
- Proporcionar una experiencia al usuario de latencia de casi cero, y una velocidad de datos de acceso similar a la fibra óptica.
- Conectar más de 100 millones de dispositivos.
- Proporcionar una optimización de recursos inteligente basada en servicios.
- Mejorar la eficiencia energética y de costos en más de cien veces.

Los autores en [1], [2] mencionan que 5G penetrará en cada elemento de la sociedad y creará un ecosistema de información centrado en el usuario. 5G permite a los usuarios nuevos servicios incluyendo: Realidad Aumentada, Realidad Virtual (AR, VR, por las siglas de los términos en inglés, *Augmented Reality* y *Virtual Reality*; respectivamente), Internet de las Cosas (IoT, por las siglas del término en inglés, *Internet of Things*), vehículos autónomos y muchos más.

Los servicios solicitados por los usuarios son tan diversos que los patrones que los distinguen como sus indicadores claves de desempeño o rendimiento (KPI, por sus siglas en inglés *Key Performance Indicator*) y de calidad (KQI, por sus siglas en inglés *Key Quality Indicators*) como su ancho de banda, latencias, pérdidas de paquetes, disponibilidad, tiempos de interrupción, etc., afectan la calidad de los servicios y la percepción de los usuarios.

Una de las formas para ayudar a una mejor experiencia de usuario y que provoque un acercamiento a los verdaderos valores de los estándares es una correcta clasificación de los servicios que se soliciten. Las variaciones en los patrones de comportamiento limitan identificar la actividad de la red.

Un operador de red necesita poder clasificar los servicios que los usuarios requieran. No se trata solo de identificar el servicio, se debe conocer los indicadores claves de desempeño (KPI) y calidad (KQI) del mismo [4]; eso permitirá entre otras cosas, que el operador asigne los recursos de red más adecuados, gestionar el desempeño y poder satisfacer las necesidades del usuario e inferir una mejor QoS/QoE. Por la heterogeneidad y requerimientos que tienen los servicios 5G, para un mejor soporte de la infraestructura de la red y una mejor QoS/QoE el operador requiere de técnicas de aprendizaje automatizado (ML por las siglas del término en inglés, *Machine Learning*) para detectar e identificar los patrones en la red relacionados con los servicios. En [4],[5] se menciona que con el conocimiento pleno de los servicios que circulan por la red, se posibilita el establecimiento y posterior cumplimiento de los Acuerdos a nivel de servicio (SLA, por las siglas del término en inglés, *Service Level Agreement*) y la automatización en todos los niveles.

1.3 Descripción del problema

Las redes 5G no son una simple evolución de las redes actuales, son redes con una gestión más compleja, sobre todo porque aún no se cuenta con suficientes datos de su operación. Para identificar los requerimientos claves de 5G, se tienen que ver desde dos puntos de vista, desde una perspectiva de usuario y desde la perspectiva del operador.

En la actualidad, los sistemas de clasificación de servicios 5G que utilizan ML tienen en cuenta los KPI como factor principal para realizar la clasificación. No obstante, es necesario considerar los indicadores KQI para lograr la mejor clasificación posible, ya que estos permiten considerar no solo la perspectiva del desempeño de la red sino adicionalmente la del usuario que solicita un servicio.

Con la finalidad de mostrar la importancia que tiene el identificar lo más preciso posible los servicios en redes de nueva generación(5G/B5G), se realiza un gráfico de dispersión para observar la distribución que tienen algunos servicios 5G seleccionados, se hizo considerando dos parámetros de KPI muy importantes: latencia E2E y *jitter*. La Figura 1, muestra como se dispersan los servicios considerados, donde cada color representa un servicio:

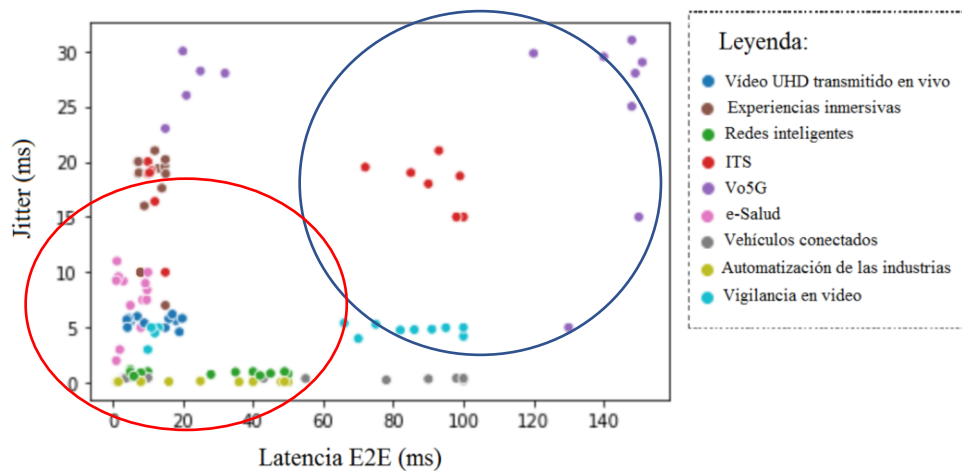


Figura 1. Distribución de los servicios 5G para KPI de latencia E2E y jitter [Elaboración propia].

De la Figura 1, se puede apreciar que los servicios 5G de Vo5G, vehículos conectados, vigilancia en video e ITS con requisitos de latencia E2E superior a los 60ms, son fáciles de identificar. Estos servicios están agrupados y se pueden distinguir a simple vista (ver círculo color azul). Sin embargo, en la medida que los requisitos de latencia E2E y *jitter* disminuyen, se puede observar (círculo rojo) que la mayoría de los servicios tienen prácticamente los mismos requisitos. Por ejemplo, se hace muy difícil para un humano identificar, sin el apoyo de un algoritmo de ML, entre los servicios de automatización de las industrias y redes inteligentes. En el capítulo 4 se detalla la programática utilizada para el análisis; por ejemplo, para generar la Figura 1 se emplea Python y la librería *Seaborn*, que tiene la

función *scatterplot*, donde se le introducen los KPI que se quieran graficar y otros parámetros de entrada de la función.

Por lo anteriormente mencionado, se evidencia la influencia e importancia de los parámetros de desempeño (KPI) y adicionalmente los de calidad (KQI) en la identificación plena de los servicios, por lo que se resalta la necesidad de contar con un sistema de clasificación de servicios 5G/B5G, el cual ayudará al operador a tener la certeza del servicio a atender, y proporcionar los recursos de red indicados para no tener un sobre aprovisionamiento, lo que ocasionará un desperdicio de recursos, o en caso contrario no suministrar los suficientes recursos y que el desempeño de la red no sea el óptimo.

1.4 Pregunta e hipótesis de investigación.

Bajo la premisa de, si se conoce con mayor certeza el servicio que solicita cursarse por una red 5G, el operador podrá gestionar y asignar, en forma más eficiente, los recursos de red que requiera y cumplir con los compromisos (SLA) y de calidad.

Al día de hoy, la carencia de información sobre los valores de los parámetros de KPI y KQI, sobre todo valores de reales de operación, constituye un reto para la elaboración de este trabajo. La documentación existente, así como los diferentes proyectos respecto al tema no definen métricas sobre los valores de los KPI y KQI de los distintos servicios, que son de vital importancia para la clasificación de servicios 5G. Empieza a surgir información por parte de los operadores sin embargo aún se tiene bajo resguardo.

La complejidad, flexibilidad, dinamismo y la correlación entre las múltiples variables de los extensos datos que se manejan en las redes 5G no se pueden hacer en un solo análisis sin ayuda computacional [6], se requiere que la red en sí sea gestionada de un modo automatizado. El aprendizaje automatizado (ML) es una de las herramientas más prometedoras en cuanto a inteligencia artificial (AI, por sus siglas en inglés *Artificial*

Intelligence) se refiere y se ha considerado su apoyo a la gestión cognitiva de las redes 5G [7].

Aseveraciones como las consideradas líneas arriba llevan a plantear la siguiente pregunta de investigación, ¿Es posible mejorar la clasificación de servicios en redes 5G al considerar adicionalmente a los parámetros de desempeño los de calidad?, afirmaciones como la planteada en la pregunta de investigación permite trabajar el tema bajo la consideración de la hipótesis siguiente; “Es posible lograr identificar en forma más plena los servicios a cursar por infraestructura de red 5G, si se consideran los parámetros claves de calidad en unión de los parámetros claves de desempeño de cada servicio bajo estudio”.

1.5 Objetivo General

El objetivo principal de este trabajo es desarrollar un sistema de clasificación de los servicios 5G, que utilice técnicas de ML. El sistema clasificador de servicios deberá manejar los parámetros claves tanto de desempeño (KPI), como de calidad (KQI) ya que se considera que, la inclusión de estos últimos llevará a una clasificación de los servicios 5G más precisa, lo que permitirá a los operadores ejecutar acciones como segmentación de la red estableciendo SLA conforme a los parámetros QoS correspondiente al servicio clasificado.

1.6 Objetivos específicos

Para alcanzar el objetivo planteado se establecen algunos objetos particulares

- De la recopilación y análisis de la información teórica, de estándares, y de resultados de proyectos que se desarrollan sobre el tema, construir el marco teórico de la investigación.
- Con el soporte de *Machine Learning* proponer un sistema para la clasificación de servicios 5G/B5G.

- Validar el sistema que se propone para clasificar servicios 5G a través de simulación comparando varios algoritmos de ML.

1.7 Secuencia de la tesis

La organización de este escrito es:

En el Capítulo 2, trata de algunas de las generalidades descriptivas alrededor de las redes 5G, se resumen las características fundamentales, así como aspectos de gestión para incidir en un mejor desempeño con énfasis en los servicios, y el despliegue de recursos que se requieren para su desempeño y cumplimiento de los SLA. Se describen los servicios que se desplegarán en la red 5G, sus características técnicas que los identifican, su clasificación. Asimismo, se definen detalles de los indicadores claves de desempeño y de calidad (KPI y KQI) intrínsecos a cada uno de los servicios, indicadores importantes para el desarrollo de este trabajo. Posteriormente, y debido a que la arquitectura 5G está basada en servicios se explica la evolución de la arquitectura actual de la red de 4ta Generación (4G) pues es necesario conocer su escalamiento. Para finalizar se analiza la aplicación de ML en la gestión de redes 5G, así como algunas de las distintas técnicas de ML aplicables para resolver un problema determinado.

En el Capítulo 3, se propone un sistema para clasificar servicios 5G, con el apoyo de ML. Se detallan cada uno de los bloques de dicho sistema, con un mayor énfasis en el bloque referido a la aplicación de ML en el sistema clasificador, por su importancia. Posteriormente se plantean un conjunto de recomendaciones para implementar el sistema que se propone.

En el Capítulo 4, se definen los escenarios para la validación del sistema propuesto para clasificar servicios apoyando en técnicas ML considerando tanto los KPI como los KQI, así como una combinación de ambos. Se emplea la simulación, bajo un entorno de desarrollo. (IDE) de *Jupyter Notebook* de la plataforma *Anaconda Navigator*, como método de validación del sistema, considerando primero solo los parámetros KPI de los servicios 5G, la

segunda simulación, incorpora los parámetros de KQI de los servicios seleccionados. Se realiza utilizando cinco algoritmos diferentes para validar los resultados obtenidos.

En el Capítulo 5, se expresan las conclusiones e ideas que llevan a reflexiones finales sobre las aportaciones y como sistema de clasificación de servicios propuesto puede trascender a la siguiente generación (6G) de redes avanzadas de comunicaciones.

Como nota importante, resaltar que este trabajo, es producto de un proyecto de colaboración interinstitucional entre tres entidades de gran prestigio: el Departamento de Electrónica y Telecomunicaciones del Centro de Investigación Científica y de Educación Superior de Ensenada (DET-CICESE), la Facultad de Ingeniería Arquitectura y Diseño de la Universidad Autónoma de Baja California (FIAD-UABC) ambas en Ensenada, B.C., México y la Facultad de Ingeniería Electrónica y Telecomunicaciones de la Universidad Tecnológica de La Habana (CUJAE) de Cuba. Como productos de este trabajo se generó una tesis de pregrado y un artículo en revista indexada.

2 CAPÍTULO: LAS REDES 5G, SUS CARACTERÍSTICAS, SERVICIOS Y LA GESTIÓN DE SU DESEMPEÑO.

2.1 Introducción

La red 5G continúa su desarrollo donde el crecimiento y la heterogeneidad de los diferentes servicios implementados en las redes 5G han experimentado un rápido crecimiento debido a sus características y especificaciones particulares. Uno de los principales desafíos tecnológicos que presenta, por la complejidad, flexibilidad y dinamismo de las redes 5G/B5G significa que deben administrarse automáticamente[6]. Por un lado, las variaciones en los patrones de comportamiento de los servicios, de los protocolos y de las tecnologías de comunicación limitan la identificación de la actividad de la red, por otro, el modelo de gestión tradicional es insuficiente. La red 5G requiere de cambios en la forma de su gestión, ya que miles de parámetros necesitan ser configurados, se deben monitorear, optimizar miles de celdas al mismo tiempo y recopilar gran cantidad de información; no solo del comportamiento humano, sino también de las máquinas. Lidar con esta gran cantidad de tareas y datos es casi imposible para las personas, según [6], por lo que es necesario aplicar soluciones de inteligencia artificial (AI) se puede utilizar para respaldar la gestión cognitiva de 5G / B5G [7], ML con una de las herramientas más prometedoras en esta área, que la red aprenda con base a modelos predictivos y pueda trabajar de forma autónoma e inteligente ya que debido a las correlaciones entre múltiples variables y los extensos conjuntos de datos manejados en un solo análisis, se requiere asistencia computacional [6].

5G es una red que se centra en los servicios, y para estas redes se identifican una gran variedad de nuevos servicios [4], algunos de ellos con características o requisitos de rendimiento y calidad muy similares que pudieran confundirse, por lo tanto, es importante en el campo de las telecomunicaciones, y particularmente en el despliegue de redes

5G/B5G, la correcta clasificación de los servicios. Una clasificación más precisa de los servicios, permite proporcionar un esquema eficiente para la asignación de recursos de la red y en consecuencia una mejor QoS y optimización de la QoE [4]. Si los servicios se clasifican sin la ayuda de ML, será inadecuada su clasificación, y serán aún más difíciles las tareas de monitorizar, controlar los recursos de la red, predecir y evitar violaciones de SLA, que pueden afectar tanto el rendimiento de QoS como la QoE percibida por los usuarios, así como el incumplimiento de los SLA, es decir, en general el desempeño de la red.

En este capítulo se muestran las generalidades de las redes 5G y aspectos de su gestión, la categorización y tratamiento de los servicios a circular por la misma, su clasificación, así como los KPI y KQI involucrados y que los caracterizan. Además, se describe la evolución a una arquitectura basada en servicios (SBA, por las siglas del término en inglés, *Service Based Architecture*).

Posteriormente se brinda un panorama general de ML y sus principales técnicas de aprendizaje. La vinculación de ML y 5G por la importancia que tiene para este trabajo, asimismo, se detalla el estado del arte de ML en la clasificación de servicios 5G.

2.2 Generalidades y gestión de la red 5G, trabajos relacionados.

Hoy en día 5G empieza a estar presente en muchos aspectos de la vida donde su implementación inició a finales de la década anterior, por ejemplo, en el hogar, trabajo, ocio y transporte. Esto se aprecia en la Figura 2, que es una figura clásica, presentada en unos de los primeros documentos visionarios de la ITU[2], donde se exponen los retos, requerimientos y expectativas de lo que sería la nueva generación de sistemas inalámbricos celulares, dicha figura representa una panorámica general de la diversidad de escenarios y servicios que se implementan en la red 5G. También se observa que 5G promete ser una tecnología habilitadora para una sociedad totalmente móvil y conectada al abordar una amplia gama de casos de uso y modelos de negocio con requisitos diversos.

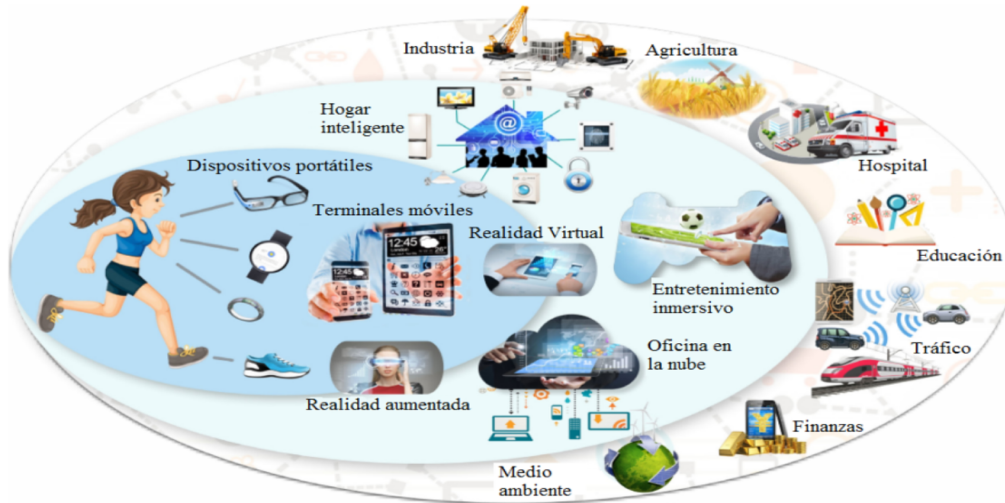


Figura 2. Visión general de 5G [1]

El rápido crecimiento del número de dispositivos móviles, del volumen de datos, y las altas tasas de datos, ha obligado a repensar el funcionamiento de la red actual (4G-LTE). El sistema 5G se pensó penetrará en cada elemento de la sociedad, creará un ecosistema de información centrado en el usuario y en todas las dimensiones, bajo un marco de interfaz unificada, una red central flexible y escalable [2]. También romperá la limitación de tiempo y espacio para permitir una experiencia de usuario inmersiva/interactiva, acortará la distancia entre lo humano y las cosas proporcionando una integración perfecta para lograr una interconexión fácil e inteligente entre las personas y las cosas [1]. Es decir, las redes 5G estarán distinguidas por tres características: ubicuidad, ultra rápida y de muy baja latencia. Según [5], la tecnología 5G desempeñará un papel importante en el empoderamiento de las transformaciones socio-económicas, mejorando la productividad, sostenibilidad, eficiencia y el bienestar general de las comunidades.

Proyectos y grupos de investigación realizan su propia definición de escenarios, casos de uso y servicios que se desarrollan en la red 5G. Esto provoca mucha confusión para los lectores, pues, por ejemplo, lo que en un escrito se denomine caso de uso, en otro se le llama servicio. Este trabajo se apoya, sin perder de vista los otros conceptos, en las

definiciones planteadas por la ITU y el IMT en [1][2] respectivamente, con la finalidad de no diversificar tanto los conceptos.

Los escenarios 5G se caracterizan, de acuerdo con [1], en: muy alta densidad de volumen de tráfico, que incluyen al menos áreas residenciales densas y torres de oficinas; muy alta densidad de conexión, ejemplo: estadios, reuniones al aire libre y subterráneos; y, por último, muy alta movilidad, típico de vías rápidas y ferrocarriles de alta velocidad.

En los últimos años se ha llegado a un consenso creciente, conforme con la ITU, de que los sistemas inalámbricos 5G soportan tres casos de uso genérico [1]. Sin embargo, se espera se amplíen y se admitan más casos de uso y aplicaciones de los establecidos en la actualidad.

Es necesario flexibilidad para adaptarse a los nuevos casos que poseerán una amplia gama de requisitos y una gran cantidad de características diferentes, dependiendo de las circunstancias y las diferentes necesidades en distintos países. En la actualidad, autores de [1] identificaron los diferentes servicios que se implementan en redes 5G y servicios relacionados con un caso de uso genérico, tales como: banda ancha móvil mejorada (eMBB), comunicación ultra confiable y de baja latencia (urLLC) y comunicación masiva tipo máquina (mMTC), que son los casos de uso genéricos establecidos por la ITU en [1] y [2] son:

a) eMBB – Banda Ancha Móvil mejorada:

Está caracterizada por un alto rendimiento, gran cobertura y móvil, se promociona como el sucesor de LTE, proporciona mejora de experiencia en todo sentido. Dentro de 5G, eMBB proporciona conexiones a dispositivos inteligentes y entrega de contenidos como video de ultra alta definición (UHD), AR/VR.

La Banda Ancha Móvil Mejorada aborda los casos de uso centrados en el ser humano para el acceso a contenido multimedia, servicios y datos. El escenario con la eMBB viene con nuevas áreas de aplicación y requisitos, además de las aplicaciones existentes para mejorar el rendimiento y una QoE de usuario más fluida. Para el caso de cobertura de área amplia, además se considera una movilidad media a alta, con una velocidad de datos de usuario mucho mayor en comparación con las

velocidades de datos existentes en 4G. El objetivo de eMBB es maximizar la velocidad de datos, garantizando una fiabilidad moderada, con una tasa de error de paquete en el orden de 10^{-3} . En resumen, los servicios móviles de banda ancha accesibles donde sea y en cualquier tiempo, para casos de uso tasas de datos muy altas, alta densidad de usuarios, y movilidad alta [8].

b) mMTC – Comunicación masiva tipo máquina:

Conectividad de un número masivo de dispositivos heterogéneos como “vestibles”, dispositivos sensores de baja potencia, etc., los cuales se pueden dividir en críticos o masivos dependiendo de sus requerimientos como caso de uso: utilerías inteligentes (*Smart utilities*), edificios inteligentes (*Smart buildings*), ciudades inteligentes (*Smart cities*), sistemas de eSalud (*eHealth*), vestibles inteligentes (*Smart wereables*), etc. [8].

Se caracteriza por una gran cantidad de dispositivos que pueden estar conectados a una misma estación base (BS) y transmiten un volumen relativamente bajo de datos no sensibles al retraso. Se requiere que los dispositivos sean de bajo costo y tengan una batería de larga duración.

c) urLLC – Comunicaciones ultra confiables y de Muy Baja Latencia:

Es la variante de LTE-m en 5G, promociona la habilidad de conexión simultánea a un número masivo de dispositivos conectados, requiere de conexiones consistente, con ancho de banda limitado.

Estas comunicaciones críticas tienen requisitos estrictos para capacidades tales como: rendimiento, latencia y disponibilidad. La tasa de transmisión urLLC es relativamente baja y su principal requerimiento es asegurar un alto nivel de confiabilidad, con una tasa de error de paquete de 10^{-5} [3]. Los casos comunes son para aplicaciones de control industrial, e Internet táctil, donde sus requerimientos tienen una fuerte demanda de interacción. Su enfoque está hacia, baja latencia,

pero alto caudal eficaz (*Throughput*), confiabilidad crítica, alta confiabilidad la cual es requerida por señales de control táctil.

Se espera que la 5G impulse la evolución de las ciudades inteligentes y el IoT mediante la implantación de un número elevado de redes de sensores de baja potencia en entornos urbanos y rurales [9]. Gracias a su seguridad y robustez, la red 5G resulta apta para la prestación de servicios de importancia crítica, tales como redes eléctricas inteligentes, servicios policiales y de seguridad, servicios públicos de suministro eléctrico e hídrico y asistencia sanitaria. Sus características de baja latencia también la hacen adecuada para la cirugía a distancia, la automatización de fábricas y el control de procesos en tiempo real.

2.2.1 Servicios sobre redes 5G

Como se mencionó, 5G es una red ideada y que está siendo implementada con enfoque a servicios, en [1] se resume gráficamente (ver Figura 3) que los servicios enmarcados dentro del triángulo, donde sus vértices denotan los casos de uso propuestos por la ITU (eMBB, mMTC y urLLC). Se puede observar algunos servicios 5G y los respectivos casos de uso genéricos con los que se relacionan servicios 5G típicos como AR y VR, videos de Ultra-Alta Definición (UHD, por las siglas del término en inglés, *Ultra High Definition*) y el servicio de hogar inteligente (smart home), se desarrollan en los escenarios planteados.

La relevancia de los requisitos esenciales específicos puede variar significativamente, según el caso de uso o el escenario en el que se implementa un servicio. La ITU en [1] Figura 3 muestra la importancia de algunos requisitos críticos con referencia a los KPI/KQI para tres casos de uso genéricos, basados en una escala con tres niveles: bajo, medio y alto. Por ejemplo, para los servicios asociados con el caso de uso de urLLC, la baja latencia es el requisito más crítico, mientras que las velocidades máximas de datos y la eficiencia energética de la red no son parámetros clave. Los parámetros KPI y KQI inciden tan fuertemente en el rendimiento de la red que consideramos fundamental incorporarlos a ambos, de forma interrelacionada, y esta es la idea que sustenta este trabajo.

Varios grupos de investigación han implementado soluciones inteligentes para abordar la necesidad de servicios de redes móviles, estandarizar ciertos métodos y mejorar el rendimiento de la red, por ejemplo, a través de la alianza de proyecto de tercera generación (3GPP, de sus siglas en inglés, *Third Generation Partnership Project*), *Next Generation Mobile Networks* (NGMN, por las siglas del término en inglés, *Next Generation Mobile Networks*), Instituto Europeo de Normas de Telecomunicaciones (ETSI, por las siglas del término en inglés, *European Telecommunications Standards Institute*) y muchas otras iniciativas de investigación[10][11].

Los autores de [11] destacaron la posibilidad de utilizar SL y algoritmos de aprendizaje no supervisados para clasificar nuevos servicios dentro de casos de uso (eMBB, mMTC y urLLC). Propusieron considerar el uso de requisitos básicos de latencia, ancho de banda y velocidad de datos como KPI.

Para la definición de los servicios 5G se consultaron varios ecosistemas de distintos proyectos y empresas que se dedican al negocio de la implementación de dichos servicios, entre los que se encuentran documentos de Huawei [12], Nokia [13], 3GPP [14], [15] y NGMN [16], [17]. Se describen algunos de los servicios que se utilizarán en este trabajo en la propuesta del clasificador de servicios 5G.

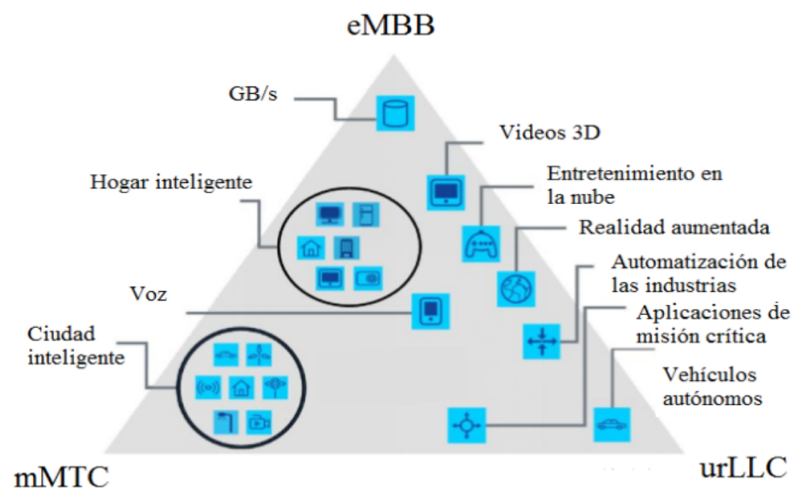


Figura 3. Ejemplos de servicios 5G y su caso de uso genéricos [1]

a. Video UHD transmitido en vivo (UHD *video streaming*)

Este es uno de los servicios más demandado por los usuarios, este servicio de entretenimiento constituye una parte importante del tráfico de Internet y, en particular, los videos bajo demanda representan la mayoría del tráfico. Los usuarios consumen medios en una creciente variedad de dispositivos que incluyen televisores, teléfonos inteligentes, tabletas, dispositivos portátiles y otros [14]. Y su demanda debe satisfacer tanto a los usuarios fijos como a los móviles

La transmisión en directo y la transmisión a demanda de contenido ganan cada vez más popularidad. Los servicios en demanda son facilitados por plataformas de medios como *YouTube, Spotify, Netflix, Amazon Prime*, etc. Esto se ve facilitado por el surgimiento de nuevas interfaces como pantallas de 4K/8K para la descarga de videos o transmisiones en directo de videos de UHD [14].

Existe otra producción de medios de UHD, que no es necesariamente la de las grandes cadenas de distribución de contenidos, sino otra variedad de fuentes conocidas como cooperativa de medios [16]. Esta se caracteriza por la integración de medios de una variedad creciente de fuentes, por ejemplo, periodismo profesional, equipos de producción, cámaras drones, redes sociales y contenido generado por el usuario. Esto es especialmente destacado porque, al ser las redes sociales su fuente de distribución, introducen una gran cantidad de tráfico, ya que las redes sociales se utilizan con frecuencia y ofrecen perspectivas más amplias y son más representativas de la opinión pública[16].

b. Experiencias inmersivas (Immerse Experience)

Los servicios de realidad extendida como VR, AR, y 3D de alta resolución; se consideran como servicios de experiencias Inmersivas porque se experimentan sensaciones nuevas increíbles. Estos servicios se habilitan mediante el uso de interfaces nuevas de usuario

(pantallas 4K/8K, VR y AR), así como mediante la combinación de información digital con la del mundo real. Permite a los participantes interactuar en tiempo real para estar juntos en un entorno de realidad virtual (VR) y/o realidad aumentada (AR) [14]. Según [17], las pantallas inmersivas de alta resolución, así como las interfaces de usuario que trabajan con los sentidos humanos más allá del audiovisual, harán que estas experiencias sean muy realistas.

3GPP define en [14] que la interacción audiovisual se caracteriza por un ser humano que interactúa con el entorno o las personas, o que controla un UE y depende de la retroalimentación audiovisual. Personas de todo el mundo que soliciten este servicio pueden compartir el mismo momento y sentir la emoción a medida que los eventos se desarrollan en tiempo real. Los proveedores de servicios también se benefician de estos servicios ya que pueden aumentar los ingresos al proporcionar transmisiones inmersivas [17].

c. Vehículos conectados (*Connected Vehicles*)

Con la llegada de los vehículos eléctricos y el progreso constante hacia la conducción automatizada, la industria automovilística está experimentando una transformación que puede redefinir las nuevas categorías de casos de uso afines con las comunicaciones móviles relacionadas con vehículos conectados, que es un motor importante para el desarrollo de 5G [17]. Dependiendo de a qué se está conectando el vehículo, será la denominación del servicio en particular, como define 3GPP en [15], si la comunicación es vehículo a todo V2X, (por las siglas del término en inglés, *Vehicles to All*), vehículo a vehículo, vehículo a infraestructura, vehículo a red y vehículo a peatón (V2V, V2I, V2N, V2P, por las siglas de los términos en inglés; *Vehicle to Vehicle*, *Vehicle to Infrastructure*, *Vehicle to Network and Vehicle to Pedestrian*, respectivamente).

Las comunicaciones V2V y V2P son esencialmente entre vehículos o entre vehículos y usuarios vulnerables de la carretera, cuyo objetivo es proporcionar información sobre la

ubicación, velocidad, u otra. V2I incluye comunicaciones entre vehículos y dispositivos de control de tráfico en la vecindad del camino. La transmisión V2N se realiza entre un vehículo y un servidor de aplicaciones V2X para proporcionar servicios conectados a los vehículos [15].

Sin embargo, NGMN concreta en [16] servicios que difieren de los de 3GPP, y que son:

- **Conducción asistida:** proporciona al conductor información útil (mapas en tiempo real para la navegación, advertencias de velocidad, peligros en la carretera) para maniobrar el vehículo, lograr un flujo de tráfico eficiente y/o prevenir o minimizar el impacto de los accidentes. Posee al menos dos componentes de relevancia en las telecomunicaciones, es decir, comunicaciones V2N para el modelado de medio ambiente a largo plazo (adquisición del último mapa digital, incluida la información y ubicación de las señales de tráfico) y comunicaciones V2X para el modelado de entorno a corto plazo (reconocimiento de objetos circundantes).
- **Conducción tele-operada:** permite la operación de un vehículo por un conductor remoto. Las áreas donde la completa conducción remota puede encontrar aplicaciones incluyen desastres, terrenos desconocidos/inesperados y entornos donde la conducción manual pone en peligro la vida como en plantas nucleares o construcciones.
- **Mediación de información:** abarca varios dominios que se basan en el procesamiento de información adquirida o informada por vehículos para proporcionar servicios como los de seguridad (rastreo de vehículos robados, control de fronteras), y otros de valor agregado como la gestión de flotas.

Estas diferencias hacen que existan ciertas particularidades en los servicios, lo cual repercute en los indicadores de desempeño o de calidad.

d. Sistemas de Transporte Inteligentes (ITS, por las siglas del término en inglés, *Intelligent Transport Systems*)

Uno de los retos de 5G es la baja latencia y seguridad, estas características desempeñan un papel importante en la evolución de los ITS, pues permite que los vehículos inteligentes se comuniquen entre sí y brinda nuevas oportunidades en el ámbito de los vehículos y camiones autónomos conectados [9]. Por ejemplo, un vehículo autónomo manejado a través de un sistema de conducción basado en la nube debe ser capaz de detenerse, acelerar o girar cuando se le indique. Todo valor de latencia en la red o pérdida en la cobertura de la señal que impida la entrega del mensaje puede tener consecuencias catastróficas.

Actualmente, la conducción autónoma de vehículos crea nuevos desafíos para las comunicaciones, para la seguridad, optimización y para la eficiencia del tráfico. Los servicios de ITS reflejan distintos casos como: [16], [18].

- La seguridad vial: incluye advertir a los usuarios de la carretera sobre colisiones o situaciones peligrosas.
- La conducción autónoma: requiere, además, la coordinación de acciones, por ejemplo, para realizar un adelantamiento.
- Los servicios de eficiencia de tráfico tienen como objetivo controlar el flujo de este en entornos urbanos. Incluye información sobre el estado de los semáforos y la situación del tráfico local, para permitir la adaptación de la velocidad del vehículo en las intersecciones.
- Servicio de entrega de drones/robots: automatiza la entrega de bienes y servicios mediante el uso de robots y vehículos aéreos no tripulados (drones).
- Centros de transporte inteligentes: En este caso se enmarcan los contextos de aeropuertos, puertos, terminal de autobuses y estación de trenes. Se utilizan: numerosos sensores, recopilación de grandes cantidades de datos, procesamiento, análisis y tecnologías de comunicación para automatizar diferentes aspectos de la operación de un centro de transportación moderno.

e. Salud electrónica (eHealth)

La salud electrónica (*eHealth*) es aquella en donde los procesos electrónicos y la tecnología de comunicación apoyan la práctica de la atención médica. La política del gobierno tiene un fuerte impacto en las regulaciones para la financiación de la atención médica y puede afectar la penetración de las innovaciones en el sector de la salud. El ecosistema de salud y bienestar se divide en varios servicios: [16]

- **Monitoreo de salud y bienestar:** implica el uso de varios tipos de sensores y/o dispositivos portátiles para rastrear indicadores relevantes para la salud. Actualmente, dichos dispositivos utilizan tecnologías de comunicación de corto alcance, como *Bluetooth* y *Wi-Fi* para conectarse a un concentrador (teléfono inteligente o una puerta de enlace hacia la línea fija) que posean la capacidad de enviar los datos a un médico, periódicamente o en tiempo real.
- **Atención médica remota:** permite consultas individualizadas, tratamiento y monitoreo de pacientes fuera de las instituciones de atención médica. Los médicos podrían monitorear remotamente y en tiempo real el progreso de un tratamiento con la ayuda de datos de sensores de salud, así como de fuentes de voz y video, y ajustar el tratamiento según sea necesario.
- **Cirugía asistida:** utiliza telepresencia y alimentación de datos para permitir que un cirujano especialista ayude de forma remota a otro cirujano o profesional médico a realizar una cirugía.
- **Cirugía remota:** permite que un cirujano opere remotamente un robot quirúrgico para realizar una cirugía en un paciente. El papel de una empresa de telecomunicaciones consiste en el aprovisionamiento del enlace de comunicación para permitir la transmisión de video y audio, así como la transferencia confiable de datos en tiempo real entre el cirujano y el robot quirúrgico remoto.

f. Automatización de las industrias (IA - Industry Automation)

Una de las fases de la conocida como Cuarta revolución industrial (4RI). La transformación en la automatización industrial está habilitada por los avances en conectividad masiva, computación en la nube, grandes análisis y automatización inteligente [13]. Los últimos planes y diseños para mejorar las fábricas se centran en aumentar la eficiencia de las líneas de producción basadas en la automatización robótica y en conectar sitios de producción distribuidos, proveedores y logística. La necesidad de esquemas de comunicación energéticamente eficientes que admitan escenarios de recopilación de datos y brinden características como la AR y los servicios remotos para permitir el intercambio de conocimientos e información es primordial en el cambiante panorama de las fábricas automatizadas [11].

Los servicios automatizados de las fábricas se caracterizan típicamente por el control en tiempo real de máquinas y sistemas en líneas de producción y fabricación rápida, donde las piezas de la máquina están en movimiento dentro de un espacio confinado. Ejemplos de tales aplicaciones se especifican en [18], e incluyen ensamblaje de alta velocidad y empaquetado. La automatización de procesos incluye aplicaciones para monitoreo y diagnóstico de elementos y procesos industriales que generalmente se extienden sobre un área grande y utilizan una gran cantidad de sensores para monitorear y controlar procesos complejos que están conectados entre sí [18].

g. Vigilancia en video (VS- Video Surveillance)

Las ciudades inteligentes, fábricas o aplicaciones ambientales que utilizan video de UHD en tiempo real y análisis basados en AI mejoran la conciencia situacional, la seguridad física y la calidad de producción [16]. Con el uso de AI, el análisis de video puede convertir transmisiones de cámara de UHD en información procesable. El análisis en tiempo real de la información adquirida a través de múltiples fuentes (cámaras de vigilancia, drones, sensores) puede reducir significativamente el tiempo de detección de eventos y mejorar la precisión de la identificación [12]. Los proveedores de servicios de telecomunicaciones

tienen la oportunidad de hacer crecer su negocio al admitir nuevos casos de análisis de video como: [13]

h. Redes inteligentes (SG-Smart Grids)

Las redes inteligentes son la tecnología de comunicación que permiten un mejor monitoreo, supervisión, administración y gestión [12]. Además, de consentir un mayor control de las redes de generación y distribución de energía, lo que conduce a una mayor disponibilidad y resistencia.

En [11] se dice que hay un nuevo impulso para hacer más eficiente la distribución y uso de energía, programando niveles apropiados de generación para minimizar las brechas entre la oferta y la demanda, y proporcionar energía solo cuando sea necesario, con lo cual se minimiza el desperdicio.

Por el lado de la oferta, existe una tendencia hacia fuentes de generación de energía descentralizadas y más pequeñas con una entrega de energía mucho menos estable. Por el lado de la demanda, existe una proliferación de dispositivos finales con diversos patrones de consumo de energía (vehículos eléctricos, dispositivos de IoT) [16]. Las tecnologías de comunicación 5G permiten la inteligencia necesaria para implementar en la nueva infraestructura la distribución de energía bidireccional y los nuevos modelos de negocio que aprovechan una mayor eficiencia en la producción, entrega, uso y coordinación de recursos energéticos limitados [11].

i. Voz sobre 5G (Vo5G, Voice over 5G)

Aunque los servicios de datos impulsan la evolución de la 5G, los servicios de comunicación de voz/video siguen siendo servicios importantes de los operadores. Al igual que en las redes de Evolución a Largo Plazo (LTE, por las siglas del término en inglés, *Long Term Evolution*), la forma de proporcionar servicios de comunicación de voz/video debe

determinarse para la comercialización de 5G [13]. La industria necesita usar Vo5G para resumir todas las soluciones de comunicación de voz/video 5G. En [12] se especifica que Vo5G debe incluir: Voz sobre Nuevo Radio (VoNR, por las siglas del término en inglés, *Voice over New Radio*) y Voz sobre LTE (VoLTE, por las siglas del término en inglés, *Voice over LTE*). 3GPP ha especificado en [14] que 5G usa la arquitectura de comunicación de voz/video 4G y aún brinda servicios de comunicación de voz/video basados en el Sistema de administración de información (IMS, por las siglas del término en inglés, *Information Management System*). La tecnología de acceso de radio 5G es NR, y la voz/video a través de la red 5G se llama voz/video de NR (VoNR).

Los operadores deben tener en cuenta los factores de varias opciones de implementación de la red 5G por, motivos como la expansión de la cobertura de la propia red y la madurez del ecosistema terminal. Cuando un UE se mueve al área donde la cobertura de la señal NR es deficiente, se debe iniciar un traspaso basado en la cobertura para implementar el inter funcionamiento con la red 4G. Luego el UE transfiere a la red LTE y esta proporciona el servicio de VoLTE [12].

2.2.2 Indicadores o parámetros claves de desempeño (KPI) y de calidad (KQI)

Se ha podido distinguir que 5G soportará una amplia gama de servicios (véase Figura 3) que, a su vez, estos servicios deben tolerar requerimientos en términos de KPI y KQI. En cierta medida, los requisitos de los diversos servicios 5G pueden ser importantes para la mayoría de los casos de uso genéricos.

Un servicio puede tener requerimientos diversos en términos de KPI y KQI, porque puede poseer características de dos casos de uso genéricos como, por ejemplo, AR que se encuentra en un término medio entre eMBB y urLLC (ver Figura 3). Sin embargo, otros servicios pertenecen a un caso de uso en específico, por ejemplo, ciudad inteligente pertenece a mMTC.

La relevancia de ciertos requisitos clave pueden ser significativamente diferente, dependiendo del caso de uso o del escenario donde se despliegue un servicio. La Figura 4 [1] muestra la importancia de algunos requerimientos clave en términos de KPI para los tres casos de uso genéricos, empleando una escala de tres niveles: bajo, medio, alto. Por ejemplo, en servicios relacionados con el caso de uso urLLC, la baja latencia es el requerimiento más importante, mientras que las velocidades de datos pico o la eficiencia energética de la red no son parámetros significativos.

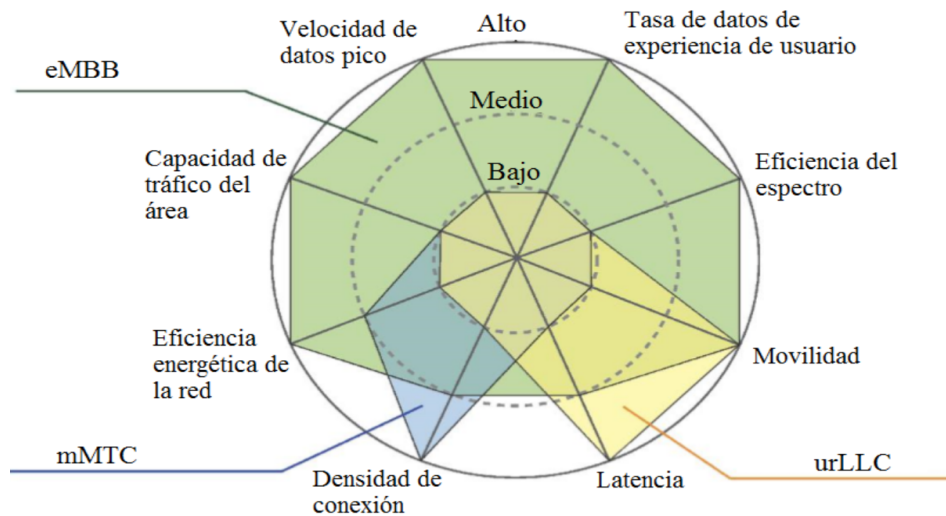


Figura 4. Importancia de algunos requerimientos claves para los casos de uso genéricos [1]

2.2.2.1 Indicadores claves de desempeño (KPI)

Los proveedores de servicios de telecomunicaciones han reportado históricamente el desempeño de sus redes contra un conjunto de KPI. Estos KPI están, por su naturaleza, centrados en la red y proporcionan poca indicación directa de la prestación de servicios de extremo a extremo (E2E, por las siglas del término en inglés, *End to End*) que permite la red. No obstante, los KPI son medidas importantes para las operaciones de red, ya que suministran indicación de rendimiento de los componentes individuales del servicio (también se debe tener en cuenta que los KPI generalmente se derivan de varias fuentes de datos y no se limitan a los datos estadísticos del rendimiento de la red) [19].

Los KPI, según [20], son la herramienta básica usada por los proveedores de servicios de telecomunicaciones para la caracterización de forma cuantitativa de los servicios, en términos de requisitos objetivos para varios parámetros fundamentales. Los KPI se diseñan para mostrar cómo es el progreso en un servicio de telecomunicaciones, por lo que son indicadores de rendimiento de estos servicios. Tienen como objetivos principales: medir el nivel de servicio, realizar un diagnóstico de la situación, comunicar e informar sobre el cumplimiento de los objetivos reflejados en los KPI, motivar a los equipos responsables de dicho cumplimiento y, en general, evaluar constantemente cualquier progreso [20].

Según [21], los KPI describen el rendimiento de la capa de red e incluyen un grupo de parámetros medibles; por lo que son el método más importante para operar y evaluar en la actualidad la gestión de red. Los KPI se pueden extraer directamente del elemento de red utilizando un sistema de gestión de red. A continuación, se listan las definiciones de algunos KPI:

a) **Latencia de E2E (*E2E Latency*)** (definida por 3GPP en [14])

El tiempo que demora transferir una determinada información de una fuente a un destino (en ms), medida en la interfaz de comunicación, desde el momento en que la fuente transmite hasta el momento en que se recibe con éxito en el destino.

b) **Fluctuación del retardo (*Jitter*)**

Se define como la variación en la demora de los paquetes recibidos. En el lado de envío, los paquetes se envían en una secuencia continua con los paquetes separados uniformemente. Si el *jitter* excede el valor establecido que hace que los paquetes se reciban fuera del rango, esto provoca que se descarten estos paquetes y tengan problemas, lo que afecta la QoS por parte de la red [14].

c) **Tasa de bits (*Bit Rate*)**

Es la tasa de bits de interés mínima garantizada que debe entregarse para garantizar una experiencia de usuario aceptable para este servicio [3].

d) Relación de pérdida de paquetes (*Packet Loss Ratio* (definida por 3GPP en [14])

En el contexto de transmisiones de paquetes en la capa de red, es el valor porcentual de la cantidad de paquetes enviados por esta capa que fueron entregados con éxito a una entidad del sistema dada dentro de la restricción de tiempo requerida por el servicio objetivo, dividido por el número total de paquetes enviados por la capa de red.

e) Velocidad de datos pico (*Peak Data Rate*) para Enlace Descendente/Ascendente (DL/UL, por las siglas de los términos en inglés, Down Link y Up Link; respectivamente)

Es la velocidad de datos teórica más alta para un solo usuario, es decir, suponiendo condiciones ideales de transmisión sin errores, cuando se utilizan todos los recursos de radio disponibles para la dirección de enlace correspondiente [22].

f) Movilidad (*Mobility*) (Según 3GPP y la ITU, en [22])

Es la velocidad máxima a la que se puede lograr una QoS definida y una transferencia sin interrupciones entre el punto de transmisión y recepción que pueden pertenecer a diferentes capas de implementación y/o Tecnologías de Acceso por Radio (RAT, por las siglas del término en inglés, Radio Access Technologies) (en km/h).

g) Confiabilidad del servicio (*Service Reliability*) (definida en [23] por 3GPP)

Es la capacidad del servicio de comunicación para desempeñarse como se requiere en un intervalo de tiempo dado, bajo condiciones establecidas. La confiabilidad puede cuantificarse utilizando medidas apropiadas, como el tiempo medio entre fallas o la probabilidad de que no existan fallas dentro de un período de tiempo específico.

2.2.2.2 Indicadores claves de calidad (KQI)

Desde el punto de vista del usuario, los KQI reflejan los indicadores de experiencia del usuario. Con estos indicadores se va de los parámetros de rendimiento tradicionales basados en la red (KPI) a los parámetros de calidad percibidos por el usuario (KQI). Sin

embargo, durante un período de tiempo, después de su definición, los KQI no fueron promovidos ni aplicados [21].

Debido a la presencia de múltiples interdependencias en toda la ruta E2E, medir la calidad del servicio no es un asunto trivial, incluso cuando se limita a la calidad objetiva en lugar de abarcar la experiencia subjetiva. Los KQI ofrecen un marco para reflejar objetivamente el rendimiento del servicio y calidad, inherentemente desde una perspectiva E2E y se pueden obtener, según [21], a través de pruebas directas y análisis estadístico de la red.

Los KQI se derivan de una serie de fuentes, incluidas las métricas de rendimiento del servicio como los KPI. Como un servicio o aplicación es compatible con una serie de elementos de un servicio, puede ser necesario determinar diferentes KPI para calcular un KQI particular. El mapeo entre los KPI y KQI puede ser simple complejo, empírico o formal [24].

Específicamente, los KQI en su definición general permiten medir y gestionar eficazmente la calidad del servicio al tiempo que separa la evaluación de la calidad en fases o categorías bien definidas, midiendo así un aspecto específico del rendimiento de la red o nivel de servicio [20]. Las diferentes categorías definidas por el Instituto Europeo de Normas de Telecomunicaciones (ETSI) y perfilado por grupo de trabajo de 3GPP indican las categorías en se dividen los KQI: [20], [25].

- **Disponibilidad de red (*Network Availability*):** la probabilidad de éxito de que las funciones de red se puedan realizar por el cliente o usuario durante un período específico.
- **Accesibilidad a la red (*Network Accessibility*):** la probabilidad de que el usuario que solicita un servicio a la red reciba la solicitud para proceder dentro de las condiciones especificadas.
- **Accesibilidad del servicio (*Service Accessibility*):** la capacidad de obtener un servicio, cuando lo solicita el usuario, dentro de los objetivos especificados.

- **Integridad del servicio (*Service Integrity*):** el grado en que un servicio se proporciona con una calidad aceptable, es decir, sin mayor deterioro, una vez obtenido.
- **Retenibilidad del servicio (*Service Retainability*):** la probabilidad de que un servicio, una vez obtenido, continúe proporcionándose en determinadas condiciones, es decir, sin interrupciones.

A continuación, se listan algunos KQI y sus definiciones:

a) Disponibilidad del servicio (*Service Availability*)

Es el valor porcentual de la cantidad de tiempo que el servicio de comunicación de E2E se entrega de acuerdo con una QoS acordada, dividido por la cantidad de tiempo que se espera que el sistema entregue al servicio E2E de acuerdo con la especificación [14]. El servicio de comunicación se considera no disponible si no cumple con los requisitos pertinentes de QoS. Pertenece a la categoría de Disponibilidad de la red.

En la disponibilidad se aplica la siguiente regla: el sistema se considera no disponible si no recibe un mensaje esperado dentro de un tiempo especificado, que como mínimo, es la suma del tiempo máximo de latencia y supervivencia de E2E [14]. Se puede decir que la disponibilidad mide la capacidad de cualquier sistema o servicio para llevar a cabo una solicitud en un momento dado e incluye todos los aspectos que tienen un impacto al respecto, como la disponibilidad física de los dispositivos.

b) Tiempo de supervivencia (*Survival Time*) (definido por 3GPP en [14])

Es el tiempo que consume y puede continuar una aplicación de un servicio de comunicación durante el envío de un paquete de E2E. Este KQI pertenece a la categoría de Retenibilidad del servicio.

c) Tasa de datos de experimentada por el usuario (*User Experience Data Rate*)

Tasa definida tanto para DL como para UL (determinada por 3GPP [14])

Es la velocidad de datos mínima requerida para obtener una experiencia de calidad suficiente.

d) Tiempo de interrupción (*Interruption Time*)

Se define como el lapso de tiempo durante el cual un UE no puede intercambiar paquetes en plano de usuario con ninguna BS durante una transmisión [20]. Este KQI pertenece a la categoría de Retenibilidad de servicio.

La intención de los KQI para la experiencia del servicio, es intentar reflejar la experiencia del cliente con indicadores que los reflejen. Con esta información, los KQI podrían reflejar fielmente la experiencia del cliente.

2.2.3 Base de datos (*dataset*) de valores de los indicadores claves de desempeño y de calidad.

En una de las definiciones clásicas de lo conocido como *dataset* se puede mencionar que es un conjunto de datos tabulados en cualquier sistema de almacenamiento de datos estructurados. En *Machine Learning* son conjuntos de datos históricos que sirven de base para entrenar un algoritmo con el objetivo de que una máquina pueda tomar decisiones. Para el caso que nos ocupa, los datos pueden ser reales, es decir, de sistemas que estén operando y arrojan información del comportamiento de dicho sistema; o también pueden ser de lo que se conoce como sintético, pues es un *dataset* creado o formado con datos extraídos de estándares, documentos/reportes técnicos de pruebas realizadas en laboratorio por entidades normativas, compañías de telecomunicaciones y/o empresas fabricantes de equipos.

Ante la dificultad de conseguir un *dataset* real con datos relevantes a este proyecto, se creó un *dataset* sintético, con datos extraídos como se indicó líneas arriba. Esto se considera una limitante. Ciertamente, entre más datos contenga, se puede considerar un número mayor de ellos y hacer más precisa una decisión. El *dataset* estará compuesto por datos inherentes

al servicio solicitado por el usuario y métricas relacionadas con los requerimientos de canal de comunicación para un mejor desempeño o *throughput*.

2.2.4 Contratos o acuerdos a nivel de servicio (SLA)

Un SLA es un acuerdo formal negociado (escrito) entre un proveedor de servicio y su cliente con la esencia de fijar el nivel acordado para la calidad de un servicio en particular. El SLA es una herramienta que ayuda a ambas partes (proveedor y cliente) a llegar a un consenso en términos del nivel de calidad del servicio, en aspectos tales como tiempo de respuesta, disponibilidad horaria, documentación disponible, personal asignado al servicio, etc. [24],[26].

Los SLA identifican y definen las necesidades del cliente a la vez que controla sus expectativas de servicio en relación a la capacidad del proveedor. Proporcionan un marco de entendimiento, simplifican asuntos complicados, reducen las áreas de conflicto y favorecen el diálogo ante la disputa. También constituyen un punto de referencia para el proceso de mejora continua, ya que el poder medir adecuadamente los niveles de servicio es el primer paso para mejorarlos y de esa forma aumentar los índices de calidad, KPI, KQI, etc. [27].

Los SLA tradicionales se enfocan casi exclusivamente en el soporte del rendimiento de la red. Sin embargo, una tendencia acelerada hacia una gestión centrada en el servicio conlleva a la necesidad de una nueva generación de indicadores que se centren en la QoS y en la QoE, en lugar del rendimiento de la red [26],[24].

Los requerimientos para establecer SLA en 5G están en función de los servicios provistos y de la infraestructura del proveedor, para formar un Objetivo de nivel de servicio (SLO, por las siglas del término en inglés, *Service Level Objectives*) es imperativo considerar tanto indicadores claves de desempeño (KPI), como de calidad (KQI) entre otros [10]. Para el establecimiento del SLA los parámetros QoS son la base, ya que están en función de las aplicaciones, de la red, así como, de factores subjetivos como es la experiencia de usuario

(QoE) [27]. En la Figura 5 se puede observar la estrecha relación entre KPI, KQI y SLA para una gestión del nivel de servicio [24].

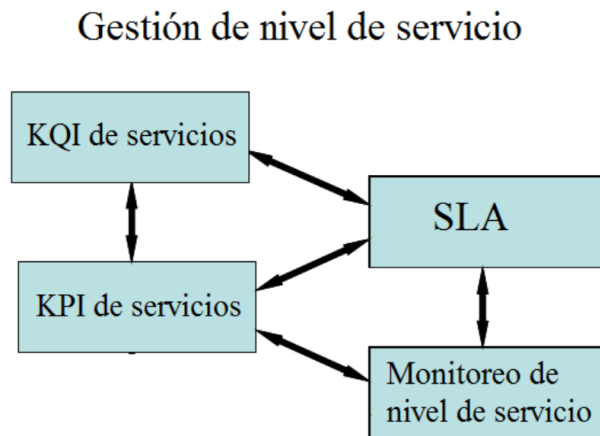


Figura 5. Relación de los SLA con los KPI y KQI [24].

La relación entre QoE y SLA, está en que QoE se relaciona con la percepción de la calidad del producto o servicio, mientras que SLA se refiere a la definición, medición e informe de medidas objetivas del servicio o producto por el usuario. Como tal, la QoE y los SLA están relacionados en el sentido de que, si la percepción del servicio es pobre, pero los parámetros del servicio caen dentro de los límites definidos por el SLA, el SLA debe ser rectificado [24]. Por tanto, la gestión eficiente de los acuerdos de nivel de servicio (SLA) y la anticipación de las infracciones de los objetivos de nivel de servicio (SLO) se vuelven obligatorias para garantizar la calidad de servicio requerida en las redes 5G [28].

Un SLA efectivo es la clave para garantizar que un proveedor de servicios/infraestructura entregue los términos de QoS acordados para los servicios de red al usuario final [27].

El marco de parámetros del SLA es una herramienta útil para categorizar parámetros involucrados. El marco organiza los parámetros de SLA en seis categorías basadas en el servicio y la tecnología con que se entrega, así como en medidas de instancia individual y su desempeño promedio. Las especificaciones de los valores específicos para los parámetros de desempeño del servicio es parte de una negociación de contrato específica.

Un SLA normalmente tiene un conjunto de objetivos asociados al nivel de servicio (SLO). Estos son los objetivos para alcanzar el nivel de servicio y, a menudo, se miden mediante un conjunto de indicadores clave de rendimiento (KPI).

En general, los SLA se pueden caracterizar por:

- Un conjunto de KPI para el servicio en cuestión, a menudo valores promediados durante un período de tiempo (por ejemplo, promedios mensuales de pérdida de paquetes).
- Una forma clara de medir esos KPI por parte del cliente o del proveedor (o ambos).
- Se establecen sanciones en caso de la ocurrencia de violaciones (p. e., reembolsos de servicios o multas).

2.3 Evolución a una arquitectura basada en servicios (SBA) en 5G

La arquitectura de redes 4G está orientada a la conexión y se basa en puntos de movilidad centralizados y fijos. Está claro que con la demanda de los servicios en 5G será necesaria otra arquitectura de redes que satisfaga justamente ese cambio. En esta sección se comentan aspectos de la arquitectura de la generación previa llamada Sistema de paquetes evolucionado (EPS, por sus siglas en inglés *Evolved Packet Systems*), es la arquitectura 4G y sus variantes LTE-avanzada y su transición a la arquitectura 5G que está orientada a servicios. Se concluye con notas que se llevan a la práctica para su implementación.

LTE es una red que solo soporta redes IP razón por la cual está diseñada para conmutación de paquetes, cuyo enfoque es proveer comunicación sin problemas entre equipos de usuarios (UE) con el protocolo IP, sin embargo, la voz, en su forma nativa utiliza conmutación de circuitos, por lo que hubo que mejorar su arquitectura, que evolucionara. Cuando se diseñó la evolución del sistema 3G, la comunidad 3GPP decidió usar el protocolo IP como el protocolo de transporte para todos los servicios, por lo que la nueva arquitectura

ya no utilizaría la conmutación de circuitos usada en sistemas GPRS/UMTS. Por lo que hubo que reemplazar las soluciones tradicionales por soluciones basadas en IP [23], [29].

En esa evolución el sistema EPS incluye lo correspondiente al equipo de usuario UE, el equipo de acceso por radio (las radio bases) que evolucionan de E-UTRAN (*enhanced UMTS Terrestrial Radio Access Network*) a e-nodeB y lo correspondiente a EPC (sistema evolucionado de paquetes en la red núcleo, de sus siglas en inglés *Evolved Packet Core*), ver Figura 6.

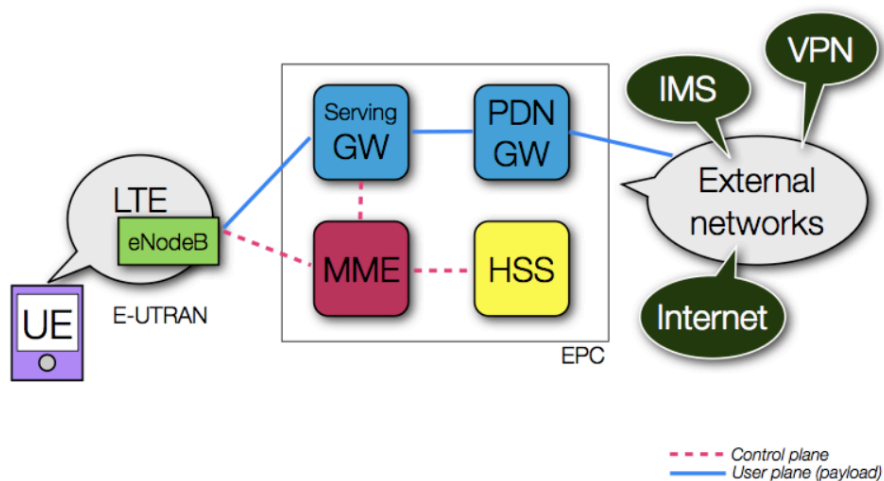


Figura 6. Arquitectura básica EPS con acceso E-UTRAN [29]

En la arquitectura de 4G la función principal del sistema EPC es proporcionar al usuario conectividad IP a la red de paquetes de datos (PDN) así como trabajar servicios de voz (VoIP), es decir manejar la carga útil eficientemente, con pocos nodos involucrados en el manejo de tráfico y evitar la conversión de protocolos. El detalle de la arquitectura se muestra en la Figura 7.

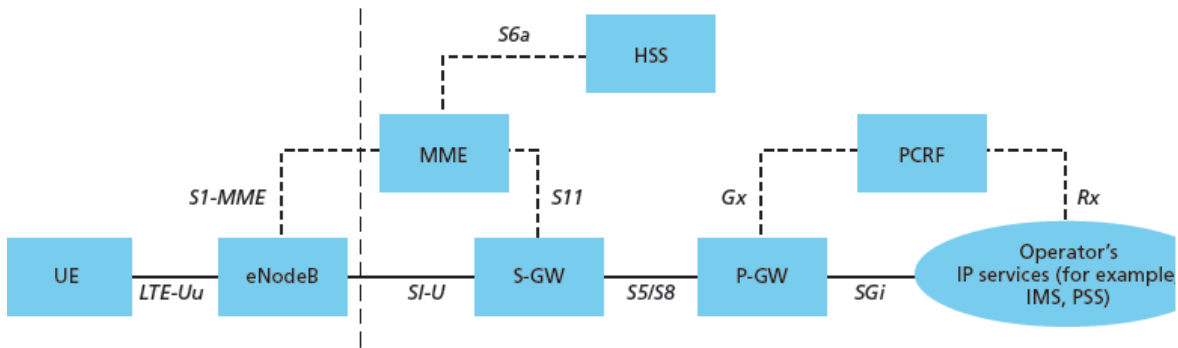


Figura 7. Arquitectura EPS 4G [23][29][22]

A continuación se describen brevemente las funciones de los componentes de la arquitectura EPS 4G [23], [29], [30].

- MME (*Mobility Management Entity*): se ocupa del plano de control. Maneja la señalización relacionada con la movilidad y seguridad para el acceso E-UTRAN.
- HSS (*Home Subscriber Server*): es una base de datos que contiene información relacionada con el usuario y con el abonado. También proporciona funciones de soporte en gestión de movilidad, configuración de llamadas y sesiones, autenticación de usuarios y autorización de acceso.
- S-GW (*Serving Gateway*): es el punto de interconexión entre el lado de radio y el EPC. Como su nombre lo indica, esta pasarela sirve al UE enrutando los paquetes IP entrantes y salientes. Es el punto de anclaje para la movilidad intra-LTE (es decir, en caso de traspaso entre eNodeB) y entre LTE y otros accesos 3GPP. Está conectado lógicamente a la otra puerta de enlace, la PDN GW.
- P-GW (*PDN, Packet Data Network Gateway*): es el punto de interconexión entre el EPC y las redes IP externas. El P-GW enruta paquetes hacia y desde los PDN. También realiza varias funciones, como la asignación de direcciones IP/prefijos IP o el control y la facturación de políticas.

Las puertas de enlace (S-GW y P-GW) se ocupan del plano de usuario. Transportan el tráfico de datos IP entre el Equipo de Usuario (UE) y las redes externas.

La arquitectura de red móvil existente se diseñó para cumplir con los requisitos de voz y servicios MBB convencionales, esta organización ha demostrado ser insuficientemente flexible para admitir servicios 5G diversificados, es así que las redes 5G se han diseñado alrededor de servicios, por lo que se han hecho múltiples actualizaciones de versiones 3GPP. La evolución de la arquitectura EPC ha causado una evolución en el núcleo de la arquitectura de 5G (basada en servicios, SBA) en dos partes:

- En la separación de los planos de control y de usuario de 4G EPC y,
- En la reorganización de las funciones de 4G EPC en servicios

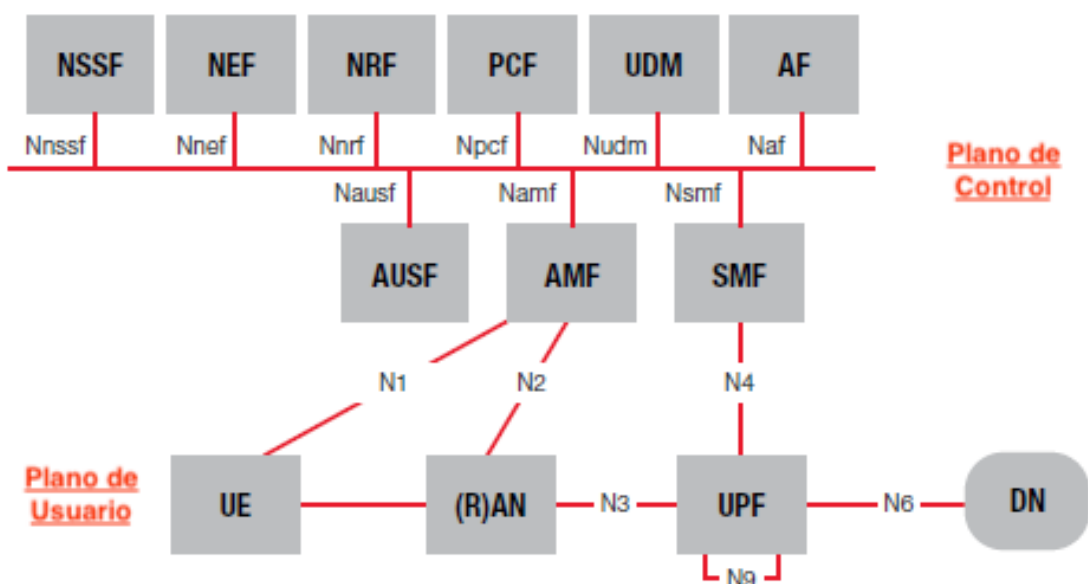
La introducción de la separación de los planos de control y usuario en 4G EPC es el primer paso hacia la arquitectura 5G. Las funciones S-GW y P-GW se dividieron en componentes de los planos de control y datos.

La reorganización de las funciones en una arquitectura basada en servicios se ha venido usando en la industria del software, donde el principio básico de esta arquitectura son la independencia de proveedores, productos, servicios y tecnologías. Adicionalmente el cómputo en la nube y la virtualización ha resultado en la disminución de costos y compartición de recursos disponibles en centros de datos. La red de núcleo (CN) de 5G se puede contraer en tamaño cuando se usa virtualización, ya que, varios componentes pueden “correr” como máquinas virtuales de comunicación. Mover el plano de control de la CN de 5G a una nube proporciona bajar costos de despliegue [30].

El núcleo de 5G es una malla de servicios interconectados lo cual se puede distinguir en la Figura 8, la arquitectura SBA está compuesta por un conjunto de elementos, dentro de cuadros, que representan las funciones de red (con sus siglas definidas en la propia figura) que se encargan de administrar el plano de usuario y de control. También se pueden observar los puntos de referencia N1, N2 y N4; estos representan conexiones desde el plano de usuario a las funciones del plano de control en la red de núcleo 5G, y el punto de referencia N3 que representa conexiones a las funciones del plano de usuario.

Las funciones de red dentro del plano de control de la red de núcleo de 5G solo utilizan interfaces basadas en servicios para sus interacciones [31], [32]. Mediante la interfaz de la RAN (N3) se transmiten paquetes de información entre el usuario demandante de un servicio y su respectiva BS [32].

La Función de gestión de sesión (SMF, por las siglas del término en inglés, *Session Management Function*) utiliza el punto de referencia N4 para controlar y administrar la Función de plano de usuario (UPF, por las siglas del término en inglés, *User Plane Function*) que maneja la ruta del plano de usuario de las secciones, incluido el reenvío y el enrutamiento de paquetes [5].



NSSF	Network Slice Selection Function	AUSF	Authentication Server Function
NEF	Network Exposure Function	AMF	Access and Mobility Management Function
NRF	Network Repository Function	SMF	Session Management Function
PCF	Policy Control Function	UE	User Equipment
UDM	Unified Data Management	(R)AN	Radio Access Network
AF	Application Function	UPF	User Plane Function
		DN	Data Network

Figura 8. Sistema de SBA de la red 5G [29][31].

La arquitectura 5G se define entonces como arquitectura basada en servicios (SBA) y la interacción entre las funciones de red dentro del plano de control y de usuario permiten que otras funciones de red autorizadas tengan acceso a sus servicios [32].

2.4 Segmentación de red (NS, *Network Slicing*)

Con el desarrollo inusitado de Internet móvil y aplicaciones multimedia, demanda de un tráfico que ha crecido increíblemente. Una red 5G requiere integrar múltiples servicios (realidad aumentada, redes sociales, juegos en línea, videos bajo demanda, etc.) cada uno de ellos con requerimientos de desempeño específicos, es decir, enfrentarse a requerimientos de servicio tan distintos, abundantes y de requisitos de QoS diferentes [33], [34], [35], como alto *throughput*, baja latencia, alta confiabilidad, movilidad y/o seguridad, esas son algunas de las razones por las que se requiere de una red con arquitectura flexible en su forma de trabajo, asimismo, de los protocolos y de las tecnologías de comunicaciones.

En ese sentido, nació un paradigma en donde se deja atrás, el que una misma infraestructura da solución al transporte de todo tipo de aplicaciones y servicios. La segmentación de la red, donde cada segmento de red (*network slice*) esté dedicada expreso para un servicio. En este trabajo se usa indistintamente el término de *network slice* o *networks slicing* así en inglés, debido a, contar con un vocablo “más preciso” cuando se trate de segmentos de red.

Hoy en día la literatura en el tema es extensa, y la coincidencia en los conceptos y propuestas son amplias, pero precisas, siempre con la idea de que las redes 5G y generaciones por venir (por ej. B5G, 6G) presenten el mejor desempeño, buscando por un lado en el uso óptimo de los recursos de los operadores y en la mejor experiencia y satisfacción de los usuarios.

En [34], [33], [5] se indican varios conceptos, definiciones y retos por los que fue concebido *networks slicing*, así como, retos y aspectos de gestión.

Networks slicing se refiere a la partición de una red física en múltiples redes virtuales, cada una con una arquitectura y optimizada para un servicio/aplicación específica, es una red lógica extremo a extremo (End-to-End), aislada, autocontenida en sus propios recursos virtuales, flujo de tráfico y reglas de aprovisionamiento [34]. Dentro de sus características fundamentales se encuentra:

- Proveer redes lógicas con mejor desempeño que las redes “*one size fit all*”, puede escalarse hacia arriba o abajo dependiendo del número de usuarios o de los requerimientos de los servicios.
- Puede aislar los servicios uno de otro, así como entre los diferentes “*slices*” en la misma infraestructura. Por lo tanto, la confiabilidad, seguridad de cada “*slice*” se mejora.
- Cada *network slice* se acondiciona de acuerdo a los requerimientos del servicio, por lo cual se optimizan los recursos físicos de la red. Esto lleva a que los servicios estén lo mejor clasificados y buscar garantizar la QoS requerida.

La segmentación de las redes considera varias partes de su arquitectura, la red de acceso de radio (RAN, del inglés *Radio Access network*), red de núcleo 5G (5G Core Network) y se puede realizar aún hasta el equipo terminal o del usuario (UE). *Networks Slicing* se basa y se apoya en los conceptos y arquitectura de redes definidas por software (SDN, del inglés *Software Defined Networks*) y en la virtualización de las funciones de red (NFV, del inglés *Network Function Virtualization*), flexibilizando la configuración virtual de los recursos de red como, el ancho de banda, procesamiento de servidores y capacidad de elementos de red. Las tecnologías SDN y NFV permiten, además de mejorar la escalabilidad, flexibilidad y dinamismo de la red, la optimización de servicios en particular, y reducir así riesgos y costos [5],[22],[36].

SDN separa el plano de control (*software*) y el plano de datos (*hardware*), y lógicamente centraliza la inteligencia de la red en el controlador. El controlador centralizado permite al

operador de red dirigir el tráfico de datos durante el tiempo de ejecución, y permite la automatización de tareas como la de configuración y la gestión de políticas [36].

NFV se aleja del principio del hardware exclusivo dedicado para funciones de red al aprovechar la tecnología de virtualización y desacopla funciones de red, p. ej., puertas de enlace (GW) o corta-fuegos (*firewalls*) del *hardware*, lo que permite implementar dichas funciones de red en servidores, conmutadores y almacenamiento estándar de alta capacidad [36]. No solo admite una reducción de costos, sino que también permite la rápida implementación de nuevos servicios y escalar flexiblemente las funciones de red según sea necesario.

En detalle, en la red de núcleo (*Core Network*), SDN y NFV virtualizan los elementos y funciones de la red en cada *slice* de la misma, para cumplir con sus propios requisitos de infraestructura. La red física del operador se divide en múltiples redes virtuales de E2E, donde cada segmento está lógicamente aislado y tiene un tratamiento dedicado en términos de rendimiento o funcionalidad [34].

Como los servicios previstos para 5G tienen demandas diferentes, hace extremadamente complejo crear una sola red capaz de soportarlos a todos, y en caso de ser posible el costo sería muy elevado [36]. Los distintos servicios que se demandan por una amplia gama de dispositivos (teléfonos inteligentes, dispositivos portátiles y sensores, entre otros) imponen requisitos sin precedentes a la arquitectura de red móvil actual de 4G, que utiliza el concepto “*one size fit all*” [26], tecnicismo que en el contexto que nos ocupa, indica que una sola infraestructura de red da cabida a todos los servicios solicitados.

En la Figura 9 [5] se muestra este concepto en una red 4G, donde todos los servicios son tratados de manera similar por la Red de acceso de radio (RAN), y luego transmitidos a la red central o red de núcleo (CN, *Core Network*). La arquitectura de la red móvil 4G hace un aprovechamiento ineficiente de sus recursos cuando los requisitos para diferentes servicios se tratan de forma similar; ya que la red no sabe diferenciar que trato brindar a cada servicio en particular [34].




Figura 9. Arquitectura de la red 4G [36]

En la Figura 10 se observa varios UE que solicitan servicios, las solicitudes se transportan por el segmento de red (*Network Slice*) que le corresponde, con la premisa de que los segmentos de red están diseñados en función de los requisitos específicos de cada caso de uso y muy en particular, para cada servicio.




Figura 10. Solicitud de servicios 5G a través de network slicing [36][11].

También se aprecia en la Figura 10 que las solicitudes transitan a través de la misma RAN. En la RAN el segmento se puede construir sobre recursos físicos y/o sobre recursos lógicos abstraídos de recursos físicos [5]. En [3], se estudian los problemas de permitir la coexistencia de los tres casos de uso heterogéneos (eMBB, mMTC y urLLC) con la misma infraestructura de RAN.

En otras palabras, *network slicing* puede ser visto como parte del paradigma de “*Network as a Service*”, introduciendo además una nueva arquitectura basada en servicios (SBA) para la red móvil 5G.

El segmentar la red en forma muy especial o *ad hoc* para cada servicio permite distribuir o asignar los recursos específicos para tal servicio, en una red lógica extremo a extremo (E2E, End-to-End) con características propias de KPI y KQI QoS, estableciendo su SLA por lo tanto el usuario experimentará su grado de satisfacción QoE y el proveedor aprovechará de mejor forma la infraestructura con que cuenta, todo esto a través de herramientas de gestión. La “semilla básica” de este proceso es contar con un conocimiento pleno de los requerimientos de los servicios solicitados por los usuarios. En tal sentido en el siguiente acápite se tratan aspectos sobre clasificación de servicios, donde las técnicas de aprendizaje automatizado (ML) plantean escenarios interesantes

2.5 Clasificación de servicios 5G, estado del arte

Como se mencionó en epígrafes anteriores, el crecimiento y la heterogeneidad de los distintos servicios que se implementarían en la red 5G, tiene un desarrollo especial debido a sus características y especificaciones particulares. Esto fue planteado en [1][2] en los casos de uso propuestos por la ITU que son soportados por 5G. La Figura 11 que enmarca los tres casos de uso propuestos por la ITU y que se denotan en cada vértice del triángulo, contiene en su interior los distintos servicios, y su ubicación depende de sus características y requerimientos de recursos de red para su funcionamiento, si se ampliara ese diagrama, sería posible saber que algunos de esos servicios tienen características similares que podrían introducir confusión y considerar un servicio cuando realmente sea otro.

En [37], [38] muestra como estos caso de uso dictan nuevos requerimientos y características (algunos comunes en su vecindad) que influyen en aspectos de confiabilidad, disponibilidad y resiliencia además de que estas características influyen en la definición e implementación del NS por lo que se tienen que tomar en cuenta.

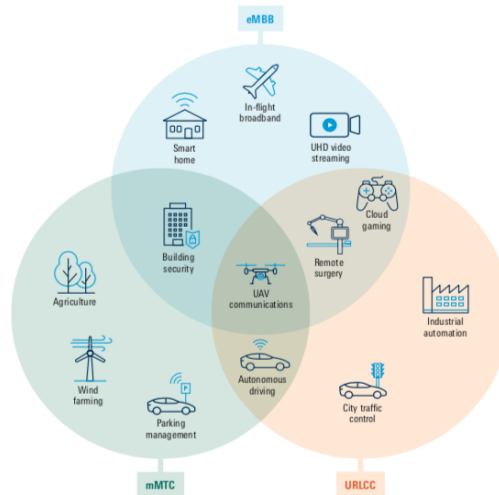


Figura 11. Casos de uso y la complejidad de las aplicaciones [37]

En el campo de las telecomunicaciones y en particular en el despliegue de redes 5G, es importante que los proveedores de servicios cuenten con la mejor clasificación de estos. La razón, es que la categorización exacta de los servicios solicitados por los UE, permite al operador asignar los recursos de red precisos llamados segmentos de red (*network slices*) para cada servicio, así como designar un SLA a cada *network slice*, mejorar la QoS de la red y la QoE percibida por los usuarios. Varios grupos de investigación implementan soluciones inteligentes para abordar servicios de redes móviles y también buscan estandarizar algunos métodos para mejorar el desempeño de las redes, como se puede ver en la alianza de 3GPP, el proyecto de Redes móviles de próxima generación (NGMN), ETSI y muchas otras iniciativas de investigación [10][11].

En [11], se destaca la posibilidad de emplear de algoritmos de SL y aprendizaje no supervisado para clasificar nuevos servicios dentro de los casos de uso (eMBB, mMTC y urLLC). Para esta clasificación el autor propone requerimientos básicos, o KPI como son: latencia, ancho de banda y tasa de datos.

En [39], se expone la posibilidad de clasificar servicios que los usuarios demanden con la ayuda de tecnologías como SDN, NFV y ML. El objetivo que se persigue por los autores es el

de predecir la demanda y asignar dinámicamente la cantidad de recursos de red [39]. Los parámetros en los que se basa esta clasificación son: ancho de banda, latencia, la variabilidad del retardo que sufre la información o *jitter* (se deja el término en inglés, ya que es un tecnicismo difícil de describir en forma literal en español) y otros KPI.

En [5] se establece un sistema para crear una base de datos donde se definan los SLA de cada *network slice*. Los autores indican el uso de técnicas de aprendizaje no supervisado para clasificar servicios 5G, como base del sistema principal. No se brinda mucha información sobre los elementos a tener en cuenta para la clasificación, pero si plantean que debe ser con requerimientos de KPI.

El grupo de investigación de *Machine Learning* en redes, (NMLRG, por las siglas del término en inglés, *Network Machine Learning Research Group*) trabaja en métodos novedosos para la clasificación de servicios 5G con el empleo de ML [40]. En algunos de los trabajos desarrollados por el NMLRG [40], los autores muestran los resultados obtenidos por los modelos que se utilizaron para la clasificación de servicios 5G, donde se enfocan en los KPI referidos al tráfico de red como factor principal para realizar la clasificación en el sistema propuesto.

Las distintas variantes que se emplean en los trabajos anteriormente mencionados se basan en la recopilación y análisis de datos con el objetivo de determinar una mejor clasificación de servicios 5G. La recopilación y análisis de los datos que se realiza en dichos trabajos se efectúa a partir de los requerimientos de KPI y ninguno utiliza los KQI como elementos a tener en cuenta para la clasificación de servicios 5G. Si se emplearan los KQI, se complicaría más el algoritmo de ML que se utilice porque aparece una nueva dimensión en el análisis de dicho algoritmo. Sin embargo, se estima que incorporar los KQI para clasificar servicios 5G ayudaría a mejorar la QoS y la QoE, haciendo más precisa la determinación y cumplimiento de los SLA. Lo que si, es insoslayable, el uso de técnicas de ML en búsqueda de la mejor clasificación.

2.6 Aprendizaje automatizado, *Machine Learning* (ML)

El término de aprendizaje automatizado (*Machine Learning*) fue definido por primera vez en 1959 por Arthur Samuel como: “El aprendizaje automatizado es el campo de estudios que da a las computadoras la habilidad de aprender si ser explícitamente programada” [41], asimismo, es una rama de la inteligencia artificial cuyo objetivo es, desarrollar técnicas que permitan a las computadoras aprender por su cuenta [42]. De forma más específica, se trata de crear programas capaces de generalizar comportamientos a partir de una información suministrada en forma de ejemplos. Por lo tanto, es un proceso de inducción del conocimiento y puede ser visto como un intento de automatizar algunas partes del método científico mediante métodos matemáticos [43]. En muchas ocasiones el campo de trabajo de ML se compara con el de la estadística computacional, ya que las dos disciplinas se basan en el análisis de datos. Sin embargo, ML también se centra en el estudio de la complejidad computacional de los problemas [43].

Explícitamente, una máquina aprende la ejecución de una tarea particular T , con el objetivo de mantener una métrica de rendimiento específica P , basada en una experiencia particular E , donde el sistema tiene como objetivo mejorar de manera confiable su rendimiento P mientras ejecuta la tarea T , explotando su experiencia E . En dependencia de cómo se especifique T , P y E , el aprendizaje se fundamenta en: minería de datos, descubrimiento autónomo o actualización de bases de datos [43].

ML ha encontrado una amplia gama de aplicaciones en procesamiento de imagen/audio, finanzas y economía, análisis de comportamiento social, gestión de proyectos, etc.; y puede ser utilizado en el modelado de varios problemas complejos de los sistemas de próxima generación, en los que las soluciones existentes requieren mucho ajuste manual, o en problemas en los que no hay ninguna solución y se utiliza un enfoque tradicional [43]. Una diferencia importante de ML sobre los algoritmos cognitivos tradicionales, es la extracción automática de características, mediante lo cual se puede renunciar a la costosa ingeniería de obtener las características a mano [39]. En términos generales, una tarea de ML puede

detectar anomalías, predecir escenarios futuros, adaptarse a entornos fluctuantes, obtener información sobre problemas complejos con grandes cantidades de datos y, en general, descubrir patrones que un humano puede pasar por alto.

ML utiliza el poder de *Big Data* (se deja el término en inglés, ya que es un tecnicismo difícil de describir en forma literal en español) y recursos informáticos para procesar patrones en datos históricos, y luego utilizarlos como funciones de predicción al analizar datos futuros [44]. Se basa típicamente en usar algoritmos matemáticos o métodos estadísticos para examinar un conjunto de datos existente y usar los resultados para obtener predicciones [39].

Un concepto clave para el entendimiento de ML y de este trabajo, es el de conjunto de datos (*dataset*), que se utiliza en el resto del capítulo. Un conjunto de datos contiene ejemplos de entrenamiento (filas) y características (columnas), y de forma general, existen dos tipos de conjuntos de datos: etiquetados y no etiquetados. El conjunto de datos etiquetado se representa por $X = \{x^{(n)} \in R^d\}_{n=1}^N$, $Y = \{y^{(n)} \in R\}_{n=1}^N$ y el no etiquetado se representa solo por $X = \{x^{(n)} \in R^d\}_{n=1}^N$ [44]. Donde X denota el conjunto de características que contiene N muestras. Cada muestra es un vector d -dimensional y se denomina vector de características, mientras que cada dimensión de un vector se denomina atributo, variable o elemento. Y representa el conjunto de etiquetas, y registra qué etiqueta se corresponde con su vector de características [44].

Un conjunto de datos normalmente se divide en: datos de entrenamiento y prueba. El conjunto de entrenamiento se usa para entrenar un algoritmo de ML y el conjunto de prueba, para asegurarse de que las predicciones del modelo predictivo generado por el algoritmo sean correctas. Al aplicar ML, el objetivo es estimar qué tan bien se generaliza un algoritmo de aprendizaje más allá de las muestras del conjunto de entrenamiento [44].

Incorporar ML para ayudar a resolver un problema conlleva un conjunto de desafíos. Los principales desafíos para la realización del presente proyecto son: la obtención de datos de alta calidad (lo que es esencial en cualquier aplicación de ML) para establecer una base de

datos y el tipo de datos (si son etiquetados o no etiquetados). Esto último es clave para decidir qué tipo de aprendizaje emplear en un proyecto de ML.

2.6.1 Esquema general de ML

El esquema general de todo problema de ML presenta dos fases de trabajo: la fase de aprendizaje y la fase de inducción, ambas se pueden observar en la Figura 12. La primera etapa, la de aprendizaje, es donde a través del descubrimiento de patrones en los datos de entrada (entrenamiento), los cuales se usan para describir los datos y posteriormente resumirlos en un modelo mediante un algoritmo de ML. En la fase dos, se induce la predicción al usar el modelo (de la fase de aprendizaje) [45]. Se prueban otros datos nunca antes vistos (los datos de entrenamiento deben ser diferentes a los de prueba); los nuevos datos se transforman en un vector de características, que se introducen en el modelo y da como resultado una predicción [45]. El objetivo del modelo de entrenamiento es minimizar el error entre las predicciones y los valores reales.

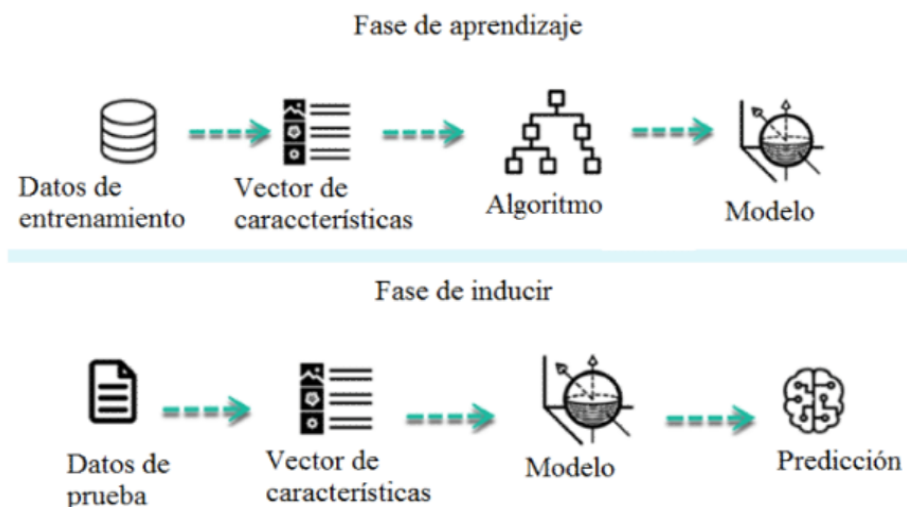


Figura 12. Fases del esquema general de un problema de ML [44].

2.6.2 Validación cruzada

De acuerdo con [19], al crear y entrenar un algoritmo de ML, el objetivo es seleccionar el que realice las mejores predicciones. Sin embargo, si se selecciona el algoritmo que presenta el “mejor” rendimiento predictivo en los datos de entrenamiento, es posible que el modelo predictivo se sobreajuste o tenga sobreaprendizaje (*overfitting*), e indica que el algoritmo de ML no se entrena bien. Este sobreajuste puede ocurrir cuando un modelo tiene patrones memorizados que aparecen en las fuentes de datos de entrenamiento y evaluación, pero falla al generalizar los patrones de los datos [46]. Para evitar que ocurra, se pueden hacer dos cosas: aumentar el volumen de la base de datos o reservar datos adicionales al dividir el conjunto de datos en tres partes (entrenamiento, validación y prueba) y con esto validar el rendimiento del algoritmo de ML [46].

Asimismo, para evaluar los resultados del análisis estadístico y validar el algoritmo en un problema de ML, se usa la técnica de validación cruzada (*cross-validation*) [47]. El objetivo de la validación cruzada consiste en estimar el nivel de ajuste de un modelo a un cierto conjunto de datos de prueba independientes de las utilizadas para entrenar el algoritmo. La validación cruzada permite garantizar que los datos de la partición entre entrenamiento y prueba sean independientes [47].

No se trata de utilizar un nuevo conjunto de datos de validación, sino consiste en emplear una validación cruzada de K-iteraciones (*K-Folds*), donde el conjunto de datos se divide en K subconjuntos [48]. Uno de los subconjuntos se utiliza como datos de prueba y el resto (K-1) como datos de entrenamiento. El proceso de validación cruzada se repite durante K iteraciones, con cada uno de los posibles subconjuntos de datos de prueba. Cada iteración produce un modelo de predicción, y por lo tanto una estimación del rendimiento de la generalización, por ejemplo, una estimación de la precisión. Una vez finalizada la validación cruzada, todos los ejemplos se han utilizado sólo una vez para evaluar, pero (K-1) veces para entrenar [48]. En la Figura 13 se representa la explicación anterior.



Figura 13. Ejemplo de validación cruzada K-Folds para 5 iteraciones [46]

2.6.3 Aprendizaje supervisado, no supervisado y reforzado

Las técnicas convencionales de ML se refieren a los tipos conocidos como: Aprendizaje supervisado, no supervisado y reforzado, así como a sus diferentes algoritmos. Se describe en forma breve estas tres técnicas que se pueden usar para implementar esquemas inteligentes de toma de decisiones en sistemas de redes de comunicaciones como 5G/B5G.

El aprendizaje supervisado (SL, por las siglas del término en inglés, *Supervised Learning*) es una técnica de ML que toma datos de entrenamiento, organizados en un vector de características de entrada (x) y un valor de salida deseado (y) para desarrollar un modelo predictivo, al inferir una función $f(x)$, devolviendo la salida predicha y [49]. Las variables (x) y (y) se les conoce como variable independiente y dependiente respectivamente. Esta técnica utiliza conjuntos de datos de tipo etiquetados y es extremadamente útil cuando la función a abordar requiere estimación o clasificación de variables. En la Figura 14 se puede apreciar un modelo genérico de SL.

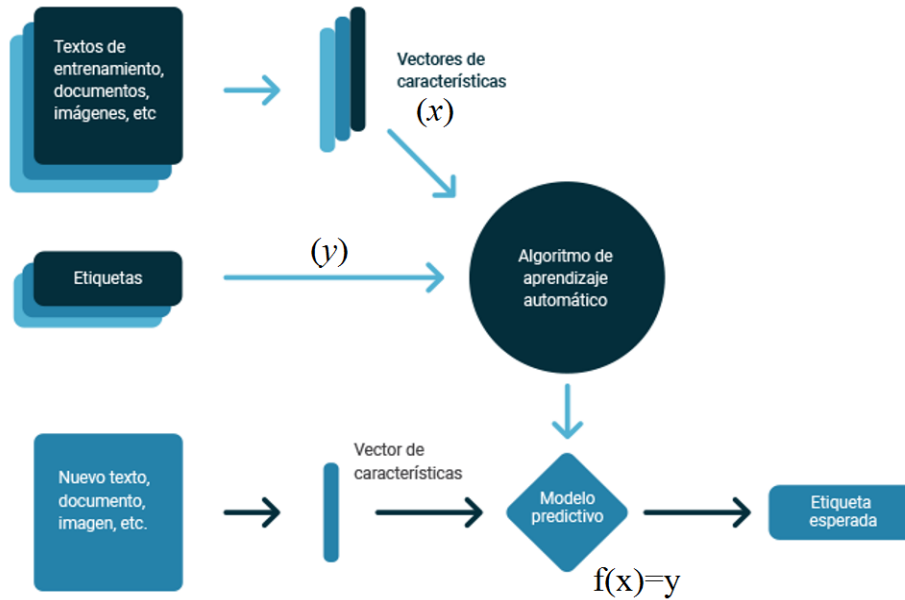


Figura 14. Modelo genérico de SL [50]

La técnica de SL tiene dos aplicaciones principales: regresión (para estimación) y clasificación. Por un lado, la clasificación, según [51], se aplica cuando el valor de salida y (en ocasiones llamadas etiquetas o categorías) que se intenta predecir es discreto. Por otro lado, se aplica la regresión cuando y es un valor continuo real. Se puede encontrar una gran cantidad de algoritmos de SL que se pueden utilizar para la clasificación y regresión. A continuación, se presentan algunos de ellos: [49]

1. **k-Vecinos más cercanos (k-NN, por las siglas del término en inglés, *k-Nearest Neighbors*)**: es un método no lineal donde la entrada consiste en las k muestras de entrenamiento más cercanas en el espacio de entrada. El resultado previsto es el promedio de los valores de sus k vecinos más cercanos.
2. **Máquinas de soporte vectorial (SVM-*Support Vector Machine*)**: están inspirados en la teoría del aprendizaje estadístico, que es una herramienta poderosa para estimar funciones multidimensionales. Para este problema, dadas m muestras de entrenamiento $((x_1, y_1), \dots, (x_m, y_m))$, el objetivo es aprender los parámetros de una función que mejor se adapte a los datos (muestras de hiperplano).

3. **Redes neuronales artificiales (ANN, por las siglas del término en inglés, *Artificial Neural Networks*)**: es un modelo de aprendizaje estadístico inspirado en la estructura de un cerebro humano, donde los nodos interconectados representan las neuronas que producen respuestas apropiadas.
4. **Árbol de decisión (DT, por las siglas del término en inglés, *Decision Tree*)**: es un modelo de diagrama de flujo en el que la capa nodo interno representa una prueba en un atributo. Cada nodo hoja representa una respuesta, y la rama representa el resultado de la prueba, Figura 15. No requieren ningún conocimiento previo de los datos, son robustos (es decir, no sufren del problema de la dimensionalidad, ya que se centran en los atributos más destacados) y funcionan bien para un conjunto de datos ruidosos.

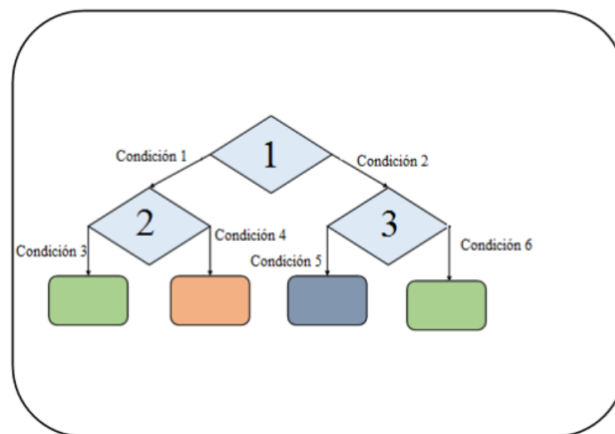


Figura 15. Ejemplo de un DT con tres nodos [10]

También se han propuesto metodologías para aprovechar al máximo los datos disponibles y aumentar el rendimiento de la predicción. Algunas de estas se clasifican entre los llamados métodos de conjuntos (*Ensemble*). Los métodos de conjunto combinan las predicciones de múltiples algoritmos de aprendizaje para producir una predicción final. Uno de estos métodos más conocidos es:

5. **Bosque aleatorio (*Random Forest*)**: es una combinación de DT predictores tal que cada árbol depende de los valores de un vector aleatorio probado independientemente y

con la misma distribución para cada uno de los árboles. Cada árbol es construido con la aplicación de la siguiente metodología: sea N el número de casos de prueba, M es el número de variables para la clasificación de etiquetas. Sea m el número de variables de entrada a ser usado para determinar la decisión en un nodo dado ($m \ll M$). Para cada nodo del árbol, elegir aleatoriamente m variables en las cuales basar la decisión. Calcular la mejor partición del conjunto de entrenamiento a partir de las m variables. Para la predicción un nuevo caso es empujado hacia abajo por el árbol. Luego se le asigna la etiqueta del nodo terminal donde termina. Este proceso es iterado por todos los árboles en el ensamblado, y la etiqueta que obtenga la mayor cantidad de incidencias es reportada como la predicción [52]. En la Figura 16 se muestra un ejemplo de un bosque aleatorio de tres árboles de decisión.

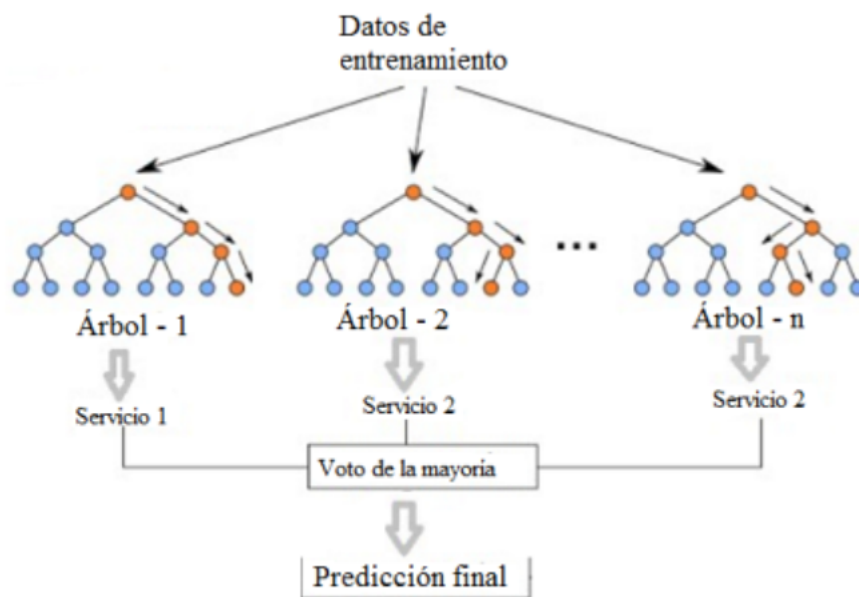


Figura 16. Ejemplo de un bosque aleatorio de tres DT [51]

2.6.4 Aprendizaje no supervisado

El aprendizaje no supervisado (*unsupervised learning*) es una técnica de ML que recibe datos de entrada sin etiquetar, con el objetivo de encontrar un patrón en ellos. En este caso, se deja que la computadora aprenda por sí misma, sin proporcionar la respuesta correcta

al problema que se quiere resolver [49]. El objetivo es construir una representación de entradas que puedan usarse para predecir a partir de entradas futuras sin dar al algoritmo la respuesta correcta, como se hace en el caso de SL [49]. En la Figura 17 se puede observar un modelo genérico de aprendizaje no supervisado:

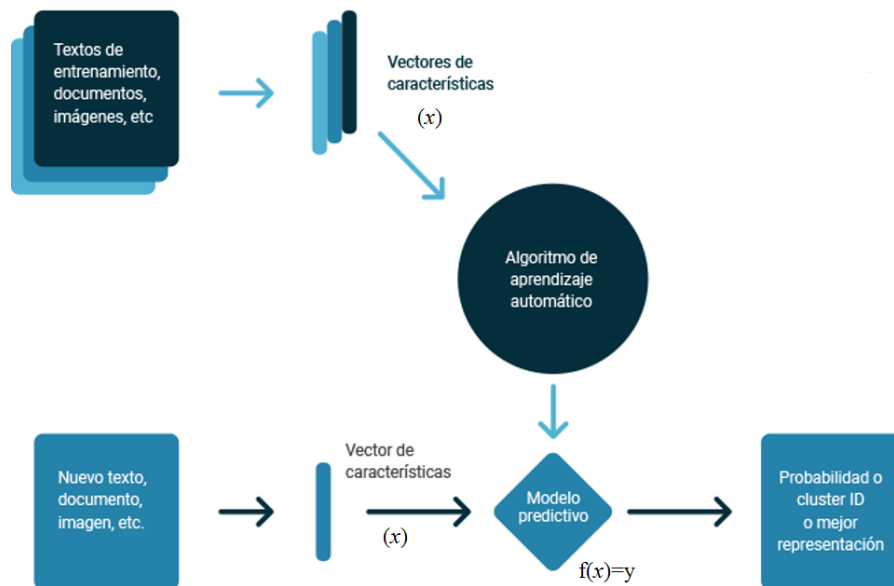


Figura 17. Modelo de aprendizaje no supervisado [50]

Se puede distinguir en la Figura 17 que, en comparación con el SL, el aprendizaje no supervisado requiere solo el conjunto de características, no el conjunto de etiquetas. Por tanto, el tipo de conjunto de datos es no etiquetado. Este tipo de aprendizaje puede ser extremadamente útil cuando se requiere identificar comportamientos anómalos, reconocer patrones o reducir la dimensionalidad de los datos. Las tres familias más importantes de aprendizaje no supervisado se pueden encontrar en [49] y son: agrupación (*clustering*), reducción de la dimensionalidad y estimación de probabilidad.

2.6.5 Aprendizaje reforzado

A diferencia del caso de SL, el aprendizaje reforzado (*reinforcement learning*) aprende de las interacciones para lograr un determinado objetivo. En muchas aplicaciones reales como: problemas de decisión y control secuenciales, no es posible proporcionar una supervisión

explícita al aprendizaje. En estos casos, solo se puede proporcionar una función de recompensa/costo, que indica cuándo el algoritmo está funcionando bien/mal [49]. El Proceso de decisión de Markov (MDP, *Markov Decision Process*) representa la base teórica para el marco del aprendizaje reforzado. En la Figura 18 se ilustra el modelo general de esta técnica de ML.

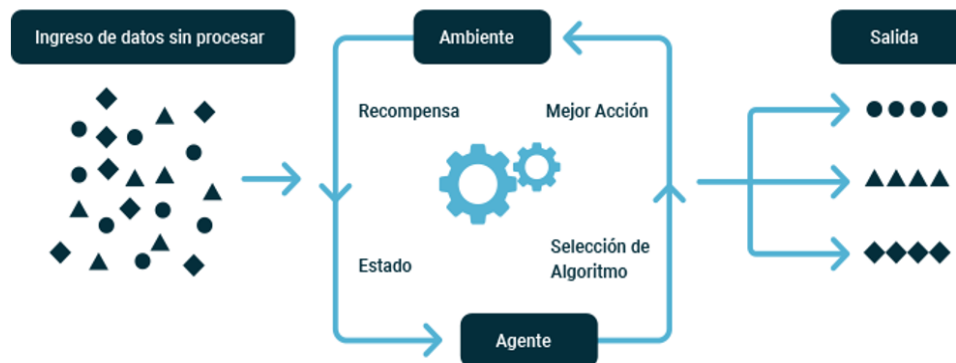


Figura 18. Modelo de aprendizaje reforzado [50].

El problema se define mediante un Proceso de decisión de Markov (MDP) $\{\mathcal{Z}, A, T, R, \gamma\}$ donde \mathcal{Z} , es el conjunto de estados posibles del entorno $\mathcal{Z} = \{z_1, z_2, \dots, z_n\}$. A , es el conjunto de acciones posibles $A = \{a_1, a_2, \dots, a_q\}$ que cada tomador de decisiones puede elegir. $T(z' | z, a)$, es la función de transición que denota la probabilidad de obtener z' dando una acción a en el estado z . $R(z, a)$ es una función de recompensa, que especifica el rendimiento inmediato esperado obtenido al ejecutar la acción a en el estado z , y además, se considera que $0 \leq \gamma \leq 1$ es un factor de descuento, que da más importancia a las recompensas inmediatas en comparación con las recompensas obtenidas en el futuro [49].

La persona (el agente) toma las decisiones e interactúa continuamente con el llamado entorno. El agente selecciona acciones, el entorno responde a esas acciones y evoluciona hacia nuevas situaciones. En particular, el entorno responde a las acciones mediante recompensas, es decir, valores numéricos que el agente intenta maximizar con el tiempo.

El agente tiene que explotar lo que ya sabe para obtener una recompensa positiva, pero también tiene que explorar para tomar mejores medidas en el futuro [49].

Casi todos los algoritmos de aprendizaje reforzado se basan en la estimación de una llamada función de valor, que considera estados que estiman qué tan bueno es que un agente esté en un estado dado [37]. Ejemplos de algoritmos de esta técnica de ML no se discuten en este trabajo, para más interés sobre ellos se puede consultar [10].

En la Figura 19 V. P. Kafle, et. Al. [11], presentan un gráfico con un resumen de la clasificación de las técnicas de ML y su aplicabilidad en redes, dicho gráfico fue extraído de datos presentados por [53].

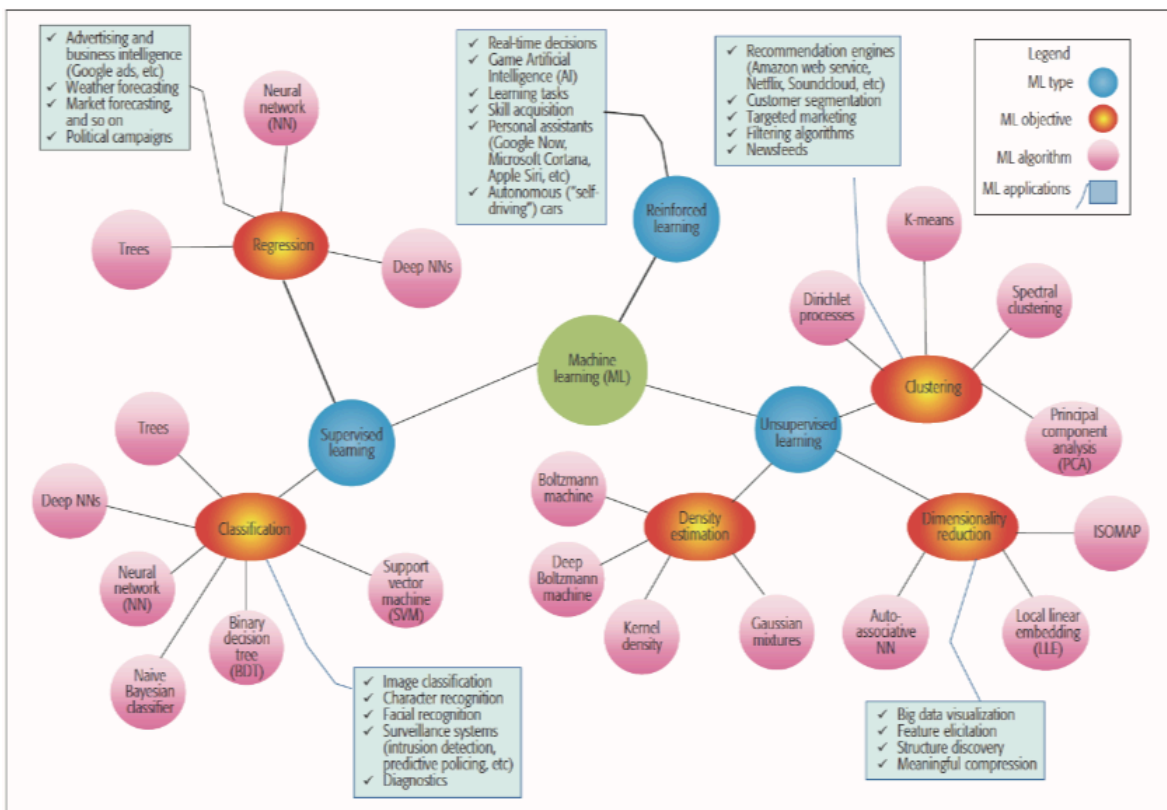


Figura 19. Clasificación de técnicas de Machine Learning para redes [11]

2.7 Aplicación de ML a la gestión de redes 5G

Los sistemas móviles e inalámbricos se han convertido en parte esencial de la infraestructura social, movilizan la vida diaria y facilitan la economía digital de múltiples maneras. Sin embargo, las comunicaciones inalámbricas y 5G se han percibido como campos de investigación diferentes de ML, a pesar del potencial que tienen cuando se usan en combinación. De hecho, la influencia de las comunicaciones de redes móviles e inalámbricas habilitadas para ML se ha hecho evidente por una serie de paradigmas de redes recientes, como: servicios basados en la ubicación, almacenamiento en caché móvil, control de tráfico de red, etc. [39]. Con la finalidad de tomar las mejores decisiones y realizar una gestión eficiente de redes 4G o 5G, ML es una herramienta potente, ya que provee información significativa proveniente del análisis de datos que se ponen disponibles a los operadores, estos datos, pueden ser utilizados en introducir mejoras a la red [49].

ML implica beneficiarse de cómo una computadora puede “aprender” de la experiencia para mejorar su habilidad de: pensar, planear, decidir y actuar, es decir, habilitar a las computadoras para que aprendan por sí solas [54]. ML ha evolucionado hasta el punto de que actualmente permite que las redes inalámbricas aprendan y extraigan conocimiento al interactuar con los datos. El interés preliminar y las discusiones sobre la viabilidad de la evolución de los estándares 5G con la ayuda de protocolos de ML captan la atención y la imaginación de ingenieros e investigadores de todo el mundo [10].

Con los avances, sin precedentes, del *software* y de la capacidad computacional, la visión de la gestión autónoma de la red se puede poner en práctica aprovechando también otros desarrollos de conocimiento interdisciplinarios en el área de ML [49]. El desafío de IMT-2020 es asegurar el rendimiento de la red y los diferentes requisitos de QoS/QoE para los casos de uso genéricos: eMBB, mMTC y urLLC. Para ello se puede utilizar, de manera efectiva, ML, lo que permite que la red aprenda de la experiencia, al tiempo que mejora el rendimiento [49].

Según [55], ML es una de las tecnologías claves a utilizar en el monitoreo de la red 5G y facilitar su auto-adaptación, ya que permite el ajuste del comportamiento en respuesta a la percepción del entorno y de los datos que ya han sido procesados. Adaptación es la “función inteligente” que puede seleccionar automáticamente diversas funcionalidades mediante el uso de diferentes componentes de software. Tales funciones no pueden basarse por completo en reglas predefinidas hechas a mano, ya que es demasiado complejo predecir las condiciones de trabajo futuras causadas por cambios en el entorno, necesitándose mecanismos automatizados [7].

El análisis de *Big Data* actualmente recibe gran atención en la investigación de la industria de las telecomunicaciones, debido a su capacidad de proporcionar información perspicaz a partir del análisis de datos ya disponibles para los operadores. ML a través del análisis de datos que se generan por la red, puede aproximar la autoconciencia al conducir la gestión de la red de reactiva a predictiva [39].

En 5G, la autoconfiguración (*self-configuration*) de la red desempeña un papel importante en la gestión de las mismas. El concepto de autoconfiguración se define según [10], como una función que monitorea de forma constante los parámetros de los equipos de la red y su entorno para, en consecuencia, actualizar dichos parámetros y con ello garantizar que la red funcione de la manera más eficiente posible.

Con la creciente complejidad de las BS en 5G el proceso de autoconfiguración es un desafío en la actualidad para los investigadores, debido a la cantidad de parámetros a considerar. Para realizar la autoconfiguración, se aplican varias técnicas de ML con el objetivo de automatizar las funciones de los equipos de red [10]. La autoconfiguración de la red, empleando tecnologías como SDN, NFV y ML, ayudan a la gestión y el análisis lo que permite resolver problemas de la red y mejorar la QoS/QoE [6].

A diferencia de lo que ocurre en 4G bajo el concepto de “*one size fit all*”, la *softwarización*, *network slicing* y la exposición de la capacidad de red proporcionan capacidades de programación dinámica para aplicaciones promulgadas por el IMT-2020. El plano de gestión

y orquestación de redes según IMT-2020 necesita detectar: cualquier falla de QoS, anomalías de eventos y realizar el proceso de gestión, con el objetivo de cumplir, asegurar y facturar los servicios en la infraestructura física y virtual, incluidos los recursos informáticos, de almacenamiento y de red, o de realizar la orquestación para lograr disposición automatizada, coordinación, creación de instancias y uso de funciones y recursos de red por criterios de optimización [56]. Con la creciente complejidad y dinamismo de los comportamientos de la red, es muy difícil con código tradicional programar recursos de red basados en el conocimiento experto, especialmente cuando no hay una relación causal matemática entre eventos de red y anomalías de QoS [3].

Las redes de comunicación actuales con arquitectura distribuida no se han diseñado para hacer frente al análisis de datos y al aprendizaje automático. La red según IMT-2020 es necesaria para soportar diversos requisitos de rendimiento en servicios heterogéneos basados en mecanismos de control de QoS unificados y de E2E [39].

Para cumplir con los requisitos de las redes según IMT-2020, los algoritmos de ML de aseguramiento de calidad de servicio necesitan datos de entrada que deben recopilarse de: los UE, la red de acceso y la red de núcleo. Dichos algoritmos también necesitan datos de KPI de QoS para construir una correlación entre KPI de QoS y datos relacionados con QoS. Sin embargo, debido a la complejidad y dinamismo de la red según IMT-2020, tales algoritmos producen datos masivos y heterogéneos. Por tanto, es necesario obtener un formato de datos unificado para que el modelo funcional de aseguramiento de QoS basado en ML funcione de manera eficiente y precisa [56].

Un mecanismo de ML que aprende de forma inteligente del entorno de red y reacciona ante situaciones dinámicas, se puede aplicar al campo de las redes según IMT-2020. Dicho mecanismo aprende de los datos anteriores de QoS contra los KPI de destino y reconstruye las relaciones entre datos anteriores relacionados con QoS y anomalías de QoS de forma automática y precisa [56]. Con el empleo de las relaciones aprendidas, estos mecanismos

pueden detectar anomalías de QoS actuales y luego pueden desencadenar la mitigación automática o acciones sugeridas.

Los mecanismos de ML también pueden predecir futuras anomalías relacionadas con la QoS [56], ya que tienen la capacidad de adaptar un sistema completo basado en datos históricos, lo que significa que en 5G, la gestión supervisa las métricas claves de la red, entiende los parámetros configurables y ajusta sus valores de manera óptima para lograr una configuración de red superior, precisada a través de un conjunto de indicadores claves de rendimiento (KPI) [7].

ML es un método de análisis de datos que automatiza la construcción de modelos analíticos, a partir de la idea de que los sistemas pueden aprender de los datos, identificar patrones y tomar decisiones con la mínima intervención humana. En [43] se especifica que ML brinda las herramientas para definir los patrones en los escenarios propuestos en IMT-2020 y mejorar la calidad de servicio (QoS) brindada por un operador de red, así como, desde una perspectiva de usuario, mejorar su calidad de experiencia (QoE). La QoE está directamente relacionada con la QoS, pero para los proveedores de servicios constituye un reto tener el conjunto adecuado de herramientas y procesos para asignar la QoS en el nivel de red a la QoE en los niveles de usuario [57].

2.8 Conclusiones

En este capítulo se puede concluir que:

- La ITU define tres casos de uso genéricos fundamentales y significativos para las redes de nueva generación como 5G/B5G: eMBB, mMTC y urLLC.
- Las redes de nueva generación, como 5G, están diseñadas para soportar servicios tan heterogéneos y con exigencias de desempeño diversas.
- Debido a que enfoque de la red 5G está basada en servicios, fue necesaria la evolución a una Arquitectura Basada en Servicios (SBA), emigrando de la arquitectura actual de 4G y LTE la cuál no satisface los requerimientos.

- Los servicios especificados para las redes de nueva generación 5G se distinguen por sus requerimientos técnicos y diversos en términos de desempeño (KPI) y de calidad (KQI).
- Se considera esencial conocer e identificar los servicios por lo que, la clasificación de los mismos resulta de gran importancia.
- La actual clasificación de servicios, basada solo en parámetros de desempeño KPI no permite la mejor gestión de los servicios 5G.
- Para la identificación y clasificación adecuada de servicios, ML ha emergido como herramientas claves, sus técnicas como aprendizaje supervisado, no supervisado y reforzado son factores claves para ello y en general para la gestión del performance de la red 5G.
- Una identificación plena de los servicios solicitados por los usuarios (a través de las UE) permitiría a los proveedores asignar los recursos de red adecuados y *ah hoc* a cada servicio

En el capítulo 3, se propone un sistema para la clasificación de servicios 5G basado en sus KPI y KQI, y se apoya en técnicas de ML con la idea de obtener mas precisión en su clasificación.



3 CAPÍTULO: PROPUESTA DE UN SISTEMA DE CLASIFICACIÓN DE SERVICIOS

3.1 Introducción

La arquitectura de las redes 5G se planteó como una red enfocada a soportar servicios, heterogéneos por lo que, la identificación y consecuente clasificación de estos requiere atención especial pues permitirá una asignación eficiente de los recursos de la red. Se ha mencionado que las redes 5G tienen una gran variedad de servicios nuevos, algunos de ellos inclusive con requerimientos de desempeño y calidad muy similares, lo cual hace difícil identificación y su clasificación. Por lo que, la automatización y en particular el aprendizaje automatizado (ML), juega un papel importante en la detección e identificación de patrones de los servicios bajo análisis. Una clasificación de servicios sin la ayuda de ML dificulta su identificación plena y la consecuente monitorización y control de los recursos de la red asignados, lo que evitaría que lleguen a funcionar correctamente, y afectaría sus prestaciones de QoS, la QoE percibida por los usuarios, así como la violación de los SLA, es decir, la gestión de la red en su totalidad.

En este capítulo se propone un sistema para clasificar servicios de redes 5G/B5G genéricos, el sistema clasificador emplea técnicas de ML. Se explica cada una de las partes del sistema clasificador de servicios partiendo de su esquema general. Dando especial énfasis al bloque relacionado con el modelo predictivo y los algoritmos de ML por la importancia que poseen en el sistema propuesto. Se considera substancial el manejo de la información inherente a los servicios, desde la creación de la base de datos, el etiquetado, su división para entrenar, probar y validar el modelo predictivo, son etapas importantes. El capítulo finaliza con recomendaciones para lograr la implementación de la propuesta.

3.2 Propuesta del sistema para clasificar servicios, su esquema general.

El esquema general del sistema que se propone para la clasificación de los servicios 5G genéricos se muestra en la Figura 20. En dicha figura se representa el momento en que un usuario o un dispositivo conectado a la red móvil 5G solicita un servicio al operador de red. Una consideración, es que en este trabajo se asume que se implementa la tecnología *network slicing* en radio de acceso a la red (RAN) de 5G, por lo que, se muestran las solicitudes a través de las UE separadas.

En el proceso de clasificación de un servicio con ML, este se pasa por un modelo predictivo, cuya entrada es un vector de características (x) formado por los KPI y KQI del servicio a clasificar. El modelo predictivo emplea la técnica de ML de SL que puede ser utilizado por un operador de red para clasificar los servicios solicitados y, con ello, distribuir eficientemente los recursos de red con los que cuenta y en consecuencia mejorar su desempeño, la calidad de los servicios y la calidad de experiencia de los usuarios. La salida del sistema que se propone es justamente un servicio clasificado con una etiqueta (y) que se espera corresponda a la clasificación correcta del servicio.

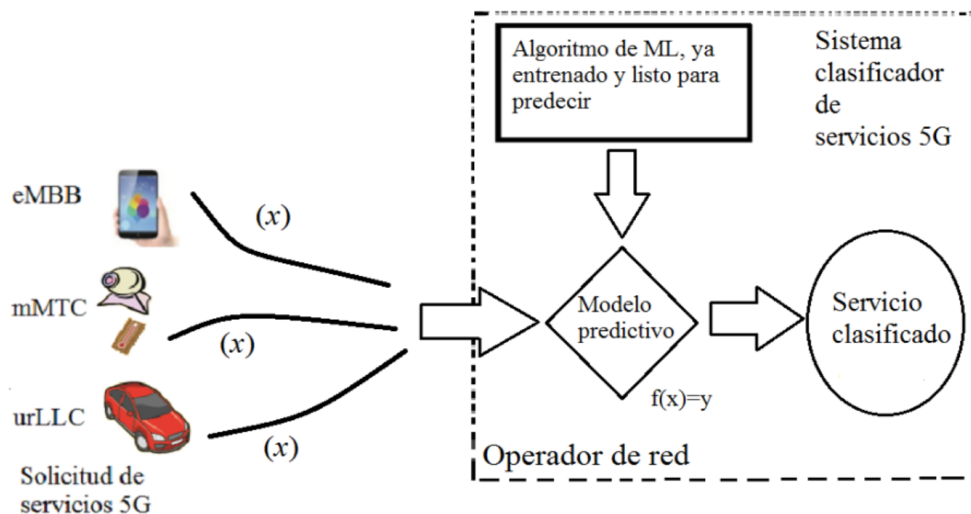


Figura 20. Esquema general del sistema propuesto para la clasificación de servicios 5G.

3.3 Construcción de la base de datos (*dataset*) de los servicios

Con el objetivo de lograr la mejor clasificación posible se propone, además de considerar los KPI como entrada principal del sistema, presentar los KQI como parámetros fundamentales de calidad de la propia red. Se infiere que con la inclusión de los KQI aparece una nueva dimensión en el análisis que ayudará a que la clasificación de los servicios sea más asertiva, con el apoyo de técnicas de ML.

La introducción de indicadores clave de calidad (KQI), que reflejan el rendimiento y la calidad del servicio de E2E, posibilitan obtener una mejor experiencia real del cliente [25]. La intención de al incorporar los KQI es tratar de mostrar la experiencia del cliente con indicadores que contengan sus requerimientos y así proporcionarles un mejor desempeño de la red y una mejor QoE. Se debe tener en cuenta que los KPI definidos en las especificaciones actuales, no se diferencian por los servicios que caracterizan, solo miden al portador de los mismos.

Uno de los principales problemas enfrentados en este trabajo, lo cual constituye una limitante, fue la obtención de un conjunto de datos con parámetros KPI/KQI de sistemas 5G/B5G en operación. Por lo tanto, se construyó un conjunto de datos sintéticos (de forma manual) analizando tanto los parámetros KPI como los parámetros KQI extraídos de documentos de estándares de la ITU, de proyectos europeos y de documentos de análisis llevados al cabo por empresas de telecomunicaciones. El conjunto de datos se construyó tomando los valores umbral consultados en la bibliografía y oscilando estos valores de forma aleatoria, provocando valores diversos para cada KPI/KQI para cada servicio individualmente.

La base de datos se creó utilizando los valores de los parámetros correspondientes a los KPI y KQI de los servicios seleccionados, los cuales se indican en el ANEXO 2. Base de datos (*dataset*) creada con valores KPI y KQI de los servicios 5G, se encuentra en formato de Valores Separados por Comas (CSV). Los documentos consultados en esta etapa están relacionados con estándares y diversos informes de proyectos sobre redes 5G, como 3GPP

[14][15][58][23], la Alianza Público-Privada 5G (5G-PPP, 5G *Public Private Partnership*) [7], NGMN [16][17], Speed [59][60], 5G America [5], la ITU [1][61][62], Huawei [12] y otros [21],[20],[18], [22], [63], [64], [65] y [66].

La elección de los servicios considerados fue en base a que fueran representativos dentro de los tres casos de uso, tal como se muestran en las Figura 3 y Figura 11. Los valores de los parámetros seleccionados fueron los valores umbral estándar, y se manipularon aleatoriamente hasta obtener valores suficientemente cercanos a sus valores límite. El anexo 2 muestra las tablas con los parámetros de umbral para los parámetros KPI/KQI extraídos.

La base de datos contiene 165 filas y 14 columnas. Las filas son los valores de los parámetros de los servicios 5G a clasificar y, las primeras 13 columnas contienen los valores de KPI y KQI, mientras que la última columna corresponde a las etiquetas de los servicios 5G. La Tabla 1 es un fragmento de la base de datos, y se pueden visualizar algunos valores de KPI, KQI y servicios 5G. Este proyecto es un trabajo en progreso, la base de datos es un proceso que puede crecer con el tiempo, la propuesta es probar la combinación de KPI + KQI, y a medida que la base de datos crezca, se probará la hipótesis.

Se elige CSV como formato de la base de datos, porque los archivos de este tipo son documentos en formato abierto y sencillo para representar datos en forma de tabla, en donde las columnas se separan por comas y las filas por saltos de línea. Además, esta extensión de archivo se maneja e implementa fácilmente en los lenguajes de programación.

El conjunto de datos está disponible bajo solicitud, en la siguiente liga por si se requiere su uso por algún proyecto bajo desarrollo Zenodo.org, o en el link <https://zenodo.org/record/4779074#.YK8rd5MzbOQ>, doi:10.5281/zenodo.4779074.

Tabla 1 Fragmento de la base de datos construida

Latency (ms)	Jitter (ms)	Bit Rate (Mbps)	Packet Loss Rate (%)	Peak Data Rate DL (Gbps)	Peak Data Rate UL (Gbps)	Mobility (km/h)	Reliability (%)	Service Availability (%)	Survival Time (ms)	Experienced Data Rate DL (Mbps)	Experienced Data Rate UL (Mbps)	Interruption Time (ms)	Service
15	5	11	0.1	18	7	260	95	99	8	1000	500	1000	UHD_Video_Streaming
5	5.5	10	1	20	10	20	95	99.2	9	990	440	2000	UHD_Video_Streaming
8	10	50	3.8	15	7	15	97	99.9	10	1000	50	0.2	Immerse_Experience
40	1	0.5	1.00e-05	18	9	0	99.92	99.999	10	5	8	0	Smart_Grid
90	18	0.2	8.00e-02	13	2	480	99.9995	99.9999	100	10	10	1000	ITS
130	5	8	9.00e-01	14	6	400	99.94	95	100	50	25	0	Vo5G
10	19	32	4.7	13	5	26	95.6	99.92	8.9	900	40	0.1	Immerse_Experience
2	3	15	8.00e-09	0.2	0.2	100	99.99996	99	1	10	100	0	e_Health
5	0.5	10	7.50e-04	0.8	0.024	80	99.9992	99	1	50	25	0	Connected_Vehicles
1	0.05	0.6	1.00e-07	15	6	28	99.999	99.9999	0	1	10	100	Industry_Automation

3.4 Propuesta de modelo predictivo y algoritmos de ML para la clasificación de servicios

La propuesta del sistema clasificador de servicios 5G/B5G se muestra en la Figura 21. Es un diagrama el cual posee varios bloques necesarios para guiar como se genera el modelo predictivo del esquema general mostrado en la Figura 20.

El esquema propuesto, opera primero fuera de línea hasta que el modelo predictivo sea validado y, aprenda a clasificar los servicios de manera efectiva con pocos errores. En una siguiente fase, sería su implementación en línea por los operadores de red donde el modelo predictivo clasifique los servicios nuevos solicitados por los UE. La salida del sistema corresponde al servicio ya clasificado el cuál se retroalimenta al algoritmo ML, lo que hace que el modelo predictivo sea más eficiente, pues su base de datos se mantiene actualizada con información de los servicios existentes. Cada una de estas fases y cada bloque se explica en la subsección 3.4.1.

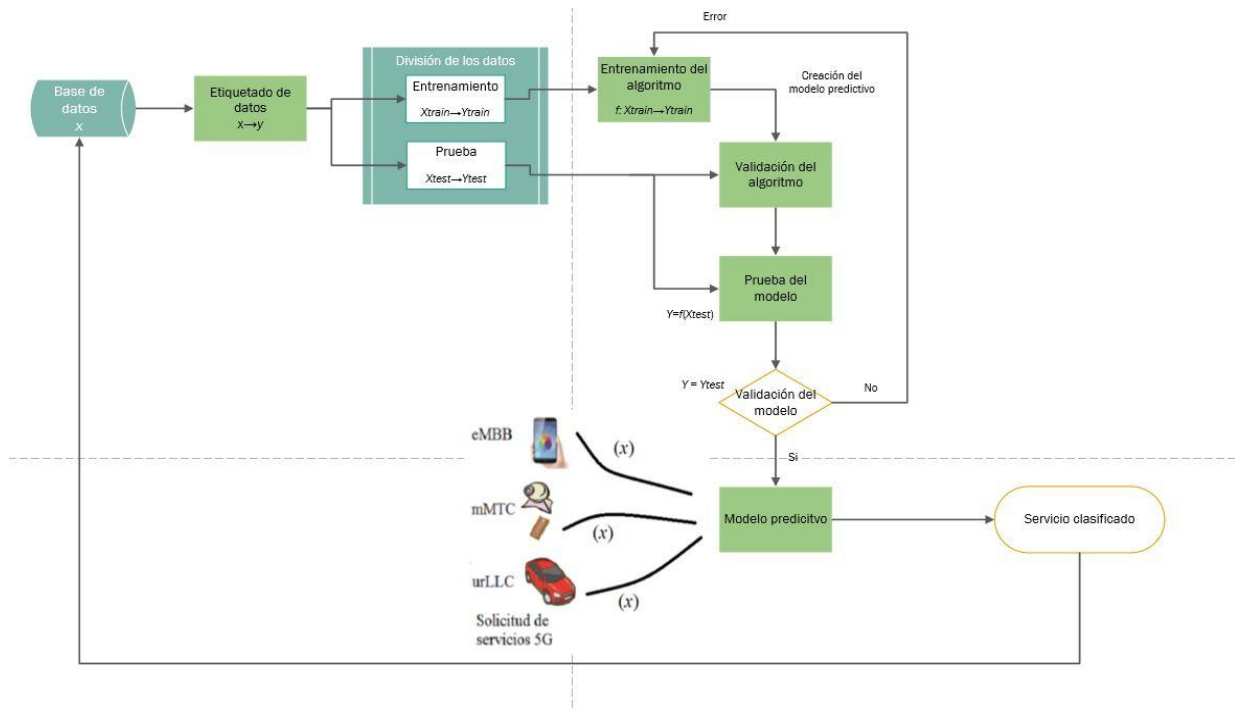


Figura 21. Diagrama en bloques del modelo predictivo empleando ML [Elaboración propia].

3.4.1 Descripción del diagrama del modelo predictivo

El primer bloque del esquema del modelo predictivo es la representación de la base de datos, en ella se encuentran datos de servicios 5G/B5G (parámetros y valores que describen sus indicadores claves de rendimiento y calidad KPI y KQI). Los datos de servicios 5G se utilizan para entrenar el algoritmo de ML y comprobar el modelo predictivo. Hay que destacar que la calidad y la cantidad del conjunto de datos (parámetros y sus valores) afecta el desempeño del entrenamiento y la predicción del modelo predictivo.

3.4.1.1 Etiquetado de los datos

En este proyecto se trabaja con un problema de clasificación donde se utilizan diferentes etiquetas (servicios 5G/B5G). Se necesita atribuir o estipular una etiqueta a los elementos a clasificar para distinguirlos. La revisión y atribución de etiquetas se puede realizar de forma manual o computacional, en el segundo de los casos se utiliza un programa diseñado

específicamente. Al aplicar ML, se emplea un conjunto de datos etiquetados con las características de los servicios para resolver un problema de clasificación de servicios 5G/B5G. Los servicios que se encuentran en la base de datos que llegan al sistema, se representan por la variable x (ver Figura 20). Al ser procesados se etiquetan (se representan por la variable Y); el etiquetado de los datos se realiza antes de crear el modelo predictivo del algoritmo, por lo que es posible saber qué etiqueta (y) corresponde a los parámetros (x) de cada servicio 5G en la base de datos (ver Tabla 1).

Para la clasificación de los servicios enfoque de este trabajo, se debe considerar la premisa: los servicios presentan una serie de parámetros (x) determinadas por los KPI y KQI que los definen y se le debe asignar de acuerdo a dichos parámetros, las etiquetas (y) correspondientes. Cabe destacar que el etiquetado de los datos se desarrolla antes de la creación del modelo predictivo, con el objetivo de que el algoritmo conozca qué etiqueta (y) corresponde a los parámetros (x) de cada servicio 5G, de la base de datos. Por tanto, no tiene sentido hablar de etiquetado de datos en el momento en que el modelo predictivo va a clasificar un servicio solicitado.

3.4.1.2 División de los datos para entrenamiento y prueba

Como se mencionó, el *dataset* es único ya que fue creado expreso para este proyecto y contiene los parámetros descriptivos de los servicios a clasificar, para el desarrollo del modelo predictivo, se requiere dividir el *dataset* en dos partes: una parte de los datos, se utiliza para entrenar el algoritmo y otra para probar el mismo. La división de la base de datos genera cuatro variables: X_{train} , X_{test} , Y_{train} y Y_{test} . La variable de entrenamiento X_{train} , se correlaciona con los valores de los servicios 5G de entrada que se seleccionaron para entrenar el algoritmo de ML y Y_{train} con sus respectivas etiquetas de salida. Las otras dos variables X_{test} y Y_{test} corresponden a las variables tanto de entrada como salida para la fase de prueba y validación del modelo predictivo. La división de los datos permite que posteriormente se pueda probar el algoritmo de ML con datos de entrada nuevos, como se explica posteriormente.

3.4.1.3 Entrenamiento del algoritmo de ML.

El modelo predictivo se describe por un proceso matemático que predice eventos o resultados futuros mediante un análisis de patrones del comportamiento pasado. El modelo predictivo representado en la Figura 20, se crea a partir de un algoritmo de ML, cuyo objetivo es crear una función $y = f(x)$ capaz de predecir el valor correspondiente a cualquier objeto de entrada x (en el sistema que se propone para la clasificación de servicios serían los KPI y los KQI de los servicios 5G). Para ello, el algoritmo de ML tiene que haber sido entrenado con un conjunto de parámetros o características de los diferentes servicios que se quieran clasificar. Esto permite que para nuevos valores de entrada (x) conocidos, se puedan asignar etiquetas nuevas (y) desconocidas, pues luego del primer entrenamiento el modelo predictivo puede proporcionar resultados para nuevos datos. Lo anterior se traduce en que una vez que el algoritmo de ML se haya entrenado, está listo para predecir o clasificar servicios solicitados.

La fase de entrenamiento, consiste en poner a disposición del algoritmo de ML datos de entrenamiento de los cuales aprende. El algoritmo de ML desarrolla una función en base a los datos de entrenamiento (X_{train}) que proporcionan la respuesta correcta (Y_{train}). En otras palabras, con X_{train} y Y_{train} se entrena el algoritmo y se genera una función $f(X_{train}) = Y_{train}$ que: identifica patrones en los datos de entrenamiento, permite asignar los atributos de los datos de entrada a los datos destino (es la respuesta que se busca predecir) y genera un modelo que captura dichos patrones.

El tiempo de entrenamiento es fundamental porque representa la cantidad de tiempo que el algoritmo necesita para entrenarse completamente y ser capaz de realizar predicciones. El entrenamiento del algoritmo de ML se puede efectuar sin conexión o fuera de línea (*offline*) lo cual se recomienda para problemas de redes. Asimismo, el entrenamiento es posible realizarlo con pruebas con conexión a Internet, aunque no se recomienda debido a que esta situación requiere de un mayor tiempo pudiendo no ser capaz de generar el

modelo predictivo y consecuentemente realizar predicciones fuera del tiempo requerido. Entrenar el algoritmo sin conexión resuelve este problema.

3.4.1.4 Validación del algoritmo de ML y prueba del modelo predictivo

Como resultado del entrenamiento del algoritmo ML se tiene un modelo predictivo que puede clasificar los servicios 5G, que se genera con los datos de *Xtrain*. Sin embargo, los datos de *Xtest* no se utilizan en el entrenamiento del algoritmo ML, lo que puede significar que el modelo predictivo generado no clasifique los servicios correctamente. Existe la posibilidad de que este modelo sea propenso a desajustarse hacia abajo (*underfitting*) o sobre ajustarse (*overfitting*) y, por lo tanto, es necesario comprobar el algoritmo ML para garantizar que el modelo predictivo sea efectivo. Si el modelo predictivo muestra un sobreajuste, no es muy útil, ya que, por ejemplo, un modelo que repita las etiquetas de las muestras que acaba de ver, lograría una puntuación perfecta, pero no sería capaz de predecir etiquetas desconocidas. Para evitar este problema, se inserta el bloque de validación del algoritmo ML, el cual aplica un método basado en la técnica de validación cruzada, descrita en el epígrafe 2.6.2.

Cuando el modelo se prueba con los nuevos datos de *Xtest*, los valores de las métricas deben ser similares a los de la etapa de validación, ya que esto indica que el algoritmo elegido funciona de manera efectiva. Es decir, si el resultado de la etapa de validación es similar a los de las etapas de evaluación y entrenamiento, el modelo entrenado es correcto y no hay indicios de sobreajuste.

Una vez que el algoritmo ha sido entrenado y validado, el siguiente paso es probar el modelo predictivo para determinar si puede predecir datos nuevos y futuros. El bloque de prueba del modelo soluciona este problema mediante la realización de una prueba de predicción con *Xtest*; y $Y = f(Xtest)$ esto se representa en la Figura 21. La salida *Y* de este bloque es un vector de los diferentes servicios 5G generados por el modelo predictivo, que corresponde a los resultados de la prueba del modelo de predicción con la variable *Xtest*.

3.4.2 Validación del modelo predictivo y sistema clasificador.

Dado que las futuras instancias tienen valores de salida (variable Y) desconocidos, no se sabe con exactitud si son los valores correctos de la predicción realizada por el modelo predictivo. Para saber qué tan asertivas son y serán las predicciones del modelo predictivo, se debe comparar la predicción Y , con los datos conocidos (de los que ya se conoce la respuesta) de destino (Y_{test}) y, utilizar esta prueba como base de precisión predictiva para futuros datos. Por lo que, la comprobación o validación del modelo predictivo se describe a partir de la comparación entre los vectores Y y Y_{test} . En caso de no ser considerada aceptable la comparación de la predicción Y con un servicio conocido, este valor se considera un “error” y se re-entrena el algoritmo; esta consideración permite que el algoritmo continúe entrenando y se tendrá que el sistema propuesto sea más preciso.

3.4.2.1 *Matriz de confusión y métricas de desempeño.*

Para validar el modelo predictivo es necesario determinar si los valores obtenidos son los esperados, para ello se utilizan diferentes métricas de desempeño, lo que permite conocer qué tan efectivo es el modelo basado en alguna métrica. Las medidas de desempeño o rendimiento se generan a partir de la relación de Y_{test} y Y , que, a su vez, crean lo que se conoce como matriz de confusión, ejemplo de la cual se muestra en la Tabla 2.

Se llama matriz de confusión porque visualiza el desempeño del modelo predictivo empleado y permite observar si se están confundiendo dos etiquetas. Las columnas de esta matriz representan el número de predicciones de cada etiqueta (Y) realizadas por el modelo predictivo, mientras que cada fila representa la etiqueta actual de los valores de prueba (Y_{test}).

Tabla 2 Ejemplo de matriz de confusión para clasificación binaria

		PREDICCIÓN (Y)	
		Positivo	Negativo
ACTUAL (Y _{test})	Positivo	Verdaderos positivos (VP)	Falsos negativos (FN)
	Negativo	Falsos positivos (FP)	Verdaderos negativos (VN)

Donde: [42]

- Verdaderos positivos (VP): El número de valores actuales clasificados como pertenecientes a una clase particular, para los cuales la predicción del modelo es correcta.
- Falsos positivos (FP): estos son los valores actuales clasificados como pertenecientes a una clase incorrecta. El modelo los considera positivos, pero la predicción es incorrecta.
- Falsos negativos (FN): son valores que pertenecen a una clase en particular, pero se clasifican de manera diferente (predicción incorrecta)
- Verdaderos negativos (VN): son observaciones que no pertenecen a una clase determinada y se clasifican correctamente.

Se puede derivar una serie de métricas a partir de los resultados de la matriz de confusión de la Tabla 2 y utilizar para evaluar el rendimiento del modelo predictivo de la siguiente manera: [32][46]

- Exactitud (*Accuracy*): Es la relación entre el número de predicciones correctas (resultados VP y VN) realizadas por el modelo y el número total de predicciones. En otras palabras, esto refleja la frecuencia con la que la clasificación del modelo predictivo es correcta. Es la medida más directa de la calidad de la clasificación,

aunque es menos apropiada cuando las etiquetas de las variables de salida no están balanceadas (datos no balanceados), es decir, las etiquetas no son de cantidades similares

$$\frac{VP + VN}{VP + FN + FP + VN} \quad (\text{Ecuación 1})$$

- Precisión (*Precision*): Mide la precisión con la que el modelo predictivo clasifica los servicios según su desempeño debido a predicciones positivas. Es la relación entre el número de predicciones correctas y el número total de predicciones predichas correctamente.

$$\frac{VP}{VP + FP} \quad (\text{Ecuación 2})$$

- Sensibilidad (*Recall*): Esta es la relación entre el número de predicciones correctas y el número total de predicciones positivas. En otras palabras, representa la sensibilidad del modelo predictivo en términos de detección de instancias positivas

$$\frac{VP}{VP + FN} \quad (\text{Ecuación 3})$$

- Puntaje F1 (*F1 score*): Este es un promedio ponderado de la sensibilidad y la precisión. Una puntuación más alta representa un mejor modelo. Por lo tanto, proporciona un buen indicador de la precisión general del modelo predictivo, mientras que la precisión y la sensibilidad proporcionan información sobre áreas explícitas.

$$\frac{2 * precision * sensibilidad}{precision + sensibilidad} \quad (\text{Ecuación 4})$$

- Coeficiente de correlación de Matthews (MCC): como una medida alternativa que no se ve afectada por el problema de los conjuntos de datos desequilibrados, MCC es la única tasa de clasificación binaria que genera una puntuación alta solo si el predictor binario pudo predecir correctamente la mayoría de las instancias de datos positivos y la mayoría de instancias de datos negativos. Va en el intervalo [-1, +1], con valores extremos -1 y +1 alcanzados en caso de clasificación errónea perfecta y clasificación perfecta, respectivamente. Al mismo tiempo, MCC = 0 es el valor esperado para el clasificador de lanzamiento de monedas [67].

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP) * (TP + FN) * (TN + FP) * (TN + FN)}} \quad \text{(Ecuación 5)}$$

Si los valores de las métricas para el modelo predictivo son satisfactorios, la fase de trabajo fuera de línea se termina y el modelo está listo para ser utilizado en línea por un operador de red para clasificar nuevos servicios solicitados por los UE. Si los resultados alcanzados en cuanto a las métricas no son los esperados, se debe repetir todo el ciclo, comenzando desde el entrenamiento del algoritmo ML, hasta que se observe una tasa de éxito razonable, para que el modelo genere menos errores en el futuro.

Una vez cumplimentadas las fases anteriores, se tiene un modelo predictivo capaz de clasificar los servicios 5G en función de sus KPI y KQI. Cuando esto se implementa en línea, los UE solicitan nuevos servicios (representados en la parte inferior de la Figura 21) y el modelo toma como entrada un vector formado por los KPI y KQI de los servicios solicitados.

Al clasificar los servicios, el sistema propuesto también utiliza una etiqueta de salida y las características (KPI/KQI) del servicio, y las retroalimenta en la base de datos del sistema. El objetivo de este enfoque es aprovechar el conocimiento de cada servicio, sus requerimientos y sus características técnicas, e incorporarlos a la base de datos enriqueciéndola y repitiendo todo el procedimiento de reentrenamiento del algoritmo ML hasta generar un nuevo modelo predictivo más robusto que brinde una mejor clasificación.

Si la validación del modelo predictivo es satisfactoria, se considera finalizada la simulación y se deben arribar a conclusiones en función de los resultados obtenidos. En el caso de que no fuese satisfactoria, se pueden tomar algunas de las siguientes acciones: aumentar el volumen de los datos para el entrenamiento del algoritmo de ML y prueba del modelo predictivo; elegir otro algoritmo de SL; hacer más complejo o más sencillo (desde un punto de vista de estructura) el algoritmo utilizado en la simulación para lograr una mejor precisión.

3.5 Servicios clasificados y su incidencia en la gestión de desempeño.

El sistema clasificador de servicios propuesto es solo una parte de un sistema completo de tratamiento de servicios 5G solicitados a través del UE. Mantener este aspecto en mente, permite inferir en la importancia del sistema clasificador. Para ilustrar lo anterior, se considera el siguiente escenario: Un usuario solicita atención a un servicio (a través del UE), se somete al sistema clasificador y la salida de éste corresponde a un servicio clasificado por el modelo predictivo (véase Figura 20). El modelo predictivo se puede equivocar, y no clasificar adecuadamente un servicio, lo que implica que el proveedor de recursos de red de telecomunicaciones haga una inadecuada asignación de recursos del *network slice* pues lo considera otro servicio. Si estas decisiones se toman para un gran número de servicios que se solicitan y llegan a una RAN (o e-nodeB), se puede hacer un sobre dimensionamiento de recursos de red (desperdicio) poniendo límites al crecimiento de segmentos. Situaciones como estas afectan el desempeño o *performance* de la red en su totalidad. Lo anterior afecta negativamente la QoS ofrecida por el proveedor de servicios por la vaguedad en la definición de los parámetros con que debe operar el servicio clasificado y, en consecuencia, afecta la QoE percibida por el usuario que lo demanda; provocando incluso el incumplimiento de los SLA. De ahí, que se requiere que el modelo se equivoque lo menos posible.

La expectativa es que, con la inclusión de los KQI el modelo predictivo acierte mucho más al clasificar servicios, que al solo considerar los KPI. La correcta clasificación de los servicios

que se soliciten por parte de los UE, provoca un acercamiento a los valores verdaderos de los estándares de los requerimientos necesarios de los servicios 5G; y es una de las formas de obtener una mejor experiencia para los usuarios.

Cuando se clasifica el servicio, el objetivo final es ayudar a inferir una mejora de las mediciones de QoS/QoE, que es lo que se quiere con el sistema de clasificación de servicios 5G propuesto. La referencia [11] plantea que una mejor determinación de las mediciones de QoS y QoE ayuda también a facilitar el empleo de la tecnología *network slicing*, que brinda grandes beneficios para la red 5G; pues se proporcionaría una cantidad óptima de recursos en cada *slice* creado. La gestión de la calidad del servicio puede mejorar la capacidad de servicio del cliente desde varios niveles según [13]. Desde el punto de vista de la gestión de QoE se mejora la percepción del usuario, que se construye a partir de sus expectativas y la satisfacción de sus necesidades; pues el operador de red o servicios puede asignar los recursos necesarios (ancho de banda, velocidad de datos, etc.) para la prestación del servicio con los requerimientos solicitado. Además, si se mide la operación y gestión diaria, se perfecciona la capacidad de detectar procesamiento de fallos; ya que es posible encontrar rápidamente los fallos de la red.

El operador de red o proveedor de servicios ofrece servicios a los clientes mediante los *network slices*. Para este propósito, los proveedores proporcionan requisitos de servicio, que representan la QoS. Contar con un servicio clasificado promueve la calidad de la red y del servicio, que en conjunto con una evaluación de mantenimiento permite mejorar la operación de la red cuando se clasifica un servicio, el operador de red puede cubrir los requerimientos necesarios para la prestación del mismo por parte de un usuario y así mejorar la QoE.

La clasificación del servicio permite al proveedor el monitoreo de la utilización de los recursos de infraestructura, y puede ajustar estos recursos según el cumplimiento de los SLA. Garantizar el cumplimiento de los SLA y desarrollar medios para la detección de violaciones de los mismos, se ha convertido en una de las mayores preocupaciones de los

operadores de red. Desde la perspectiva de éste, algunos de los beneficios que trae consigo la propuesta de clasificación de servicios incluyen: reducir el tiempo para implementar un nuevo servicio, aumentar la rentabilidad y mejorar la satisfacción del cliente; cumpliendo con los SLA. Desde la perspectiva de los clientes, estos obtienen el servicio solicitado con una experiencia de latencia de casi cero, con lo que se mejora la QoE percibida por los usuarios.

Otra de las funciones que puede realizar el operador cuando se clasifica un servicio, es desde el punto de vista de operación y administración, de acuerdo con [11], es la asignación dinámica de recursos de red. Los recursos de la red se asignan según la demanda en función del número de usuarios activos o la importancia del servicio. Un ejemplo de lo expuesto puede ser el caso en que se comparten recursos limitados entre servicios de emergencia y de entretenimiento, donde se ejecuta una asignación de recursos con mayor prioridad a los servicios de emergencia cuando su demanda aumenta.

3.6 Recomendaciones para implementar el sistema de clasificación de servicios 5G que se propone

Para implementar el sistema de clasificación de servicios 5G que se propone se debe seleccionar: el algoritmo de ML que generará el modelo predictivo del sistema que proporcione las mejores métricas de desempeño, la base de datos necesaria para el entrenamiento del algoritmo de ML, el lenguaje de programación a emplear y la plataforma software donde se simulará la propuesta.

Previo de seleccionar el algoritmo de ML, se debe conocer qué tipo de problema se quiere solucionar. La esencia de este trabajo es la clasificación de servicios 5G/B5G, su identificación que desfogue en una asignación de recursos óptima y en consecuencia un funcionamiento de los servicios sobre la red, con una gestión, monitorización y vigilancia de QoS y los SLA.

El clasificador empleado en el sistema que se propone pertenece a la técnica de SL y utiliza los datos de entrenamiento para comprender cómo las variables de entrada dadas se relacionan con la etiqueta (servicio 5G).

Para la selección del algoritmo de ML de SL a emplear, se debe tener en cuenta sus propiedades y características, así como su precisión de acierto, lo cual depende del método que emplee, pues en dependencia de este la distribución de los datos de entrada y la naturaleza de los mismos puede afectar los cálculos que el algoritmo realice. Un criterio que se puede utilizar para la elección del algoritmo de ML son las métricas de evaluación del desempeño del modelo predictivo. En la Tabla 3 se puede apreciar el comportamiento de algunas características para varios de los algoritmos de SL de ML que se pueden implementar en este tipo de problemas de clasificación, lo cual es útil para seleccionar el que se empleará en el sistema que se propone.

Tabla 3. Análisis de las características de algunos algoritmos de SL de ML [10].

Algoritmo de ML	Escalabilidad	Tendencia a sobreaprendizaje	Dificultad de programación	Tiempo para aprender	Tiempo para predecir
DT	Alta	Muy alta	Poca	Poco	Poco
Bosque Aleatorio	Muy alta	Promedio	Promedio	Alto	Alto
SVM	Media	Promedio	Alta	Alto	Poco
ANN	Media	Promedio	Muy alta	Alto	Poco
k-NN	Baja	Alta	Fácil	Alto	Depende del valor de k

Como se observa en la Figura 21, para el entrenamiento del algoritmo de ML que se emplee se necesita una base de datos, la cual debe contener los valores de los KPI y KQI de los distintos servicios 5G a clasificar. De esta forma, al entrenar el algoritmo de ML con esta base de datos, el modelo predictivo será capaz de clasificar un servicio para otros valores de x (véase Figura 20) desconocidos; es decir, valores de KPI y KQI que no estén guardados en la base de datos. El formato de esta base de datos puede ser: Excel, Valores separados por coma (CSV, por sus siglas del término en inglés, *Comma Separated Values*), u otro.

Para seleccionar el lenguaje de programación a emplear al implementar el sistema de clasificación 5G que se propone, es importante conocer las diferencias y singularidades de

estos; sus ventajas e inconvenientes, en función de la plataforma para la cual se desarrolle el proyecto. Una encuesta de la IEEE [68] señala que, como tendencia, los lenguajes de código abierto son los preferidos por los desarrolladores al permitir estudiar, modificar y mejorar el código, logrando independencia tecnológica. También en [48] se establece una comparación entre algunos de los principales lenguajes de programación como: *Ruby*, *Python*, *JavaScript*, etc.; los cuales son de interés en este trabajo. Se seleccionó Python por su facilidad de uso, adaptabilidad, cantidad de librerías, así como diversas rutinas implementadas.

A la par de elegir el lenguaje de programación que se empleará, se debe escoger la plataforma de desarrollo que se utilizará; pues ésta constituye el ambiente o entorno de software común en el cual se desenvuelve la programación de un grupo definido de aplicaciones y está vinculada a la familia de los lenguajes de programación. En este trabajo se busca emplear plataformas de desarrollo de código abierto, existiendo varias disponibles para la programación en el campo de ML. Su selección viene dada primeramente por la elección del lenguaje de programación y luego por otros criterios como: sistema operativo y características de interés que poseen. Algunas de las principales plataformas de desarrollo para proyectos de ML son: *TensorFlow*, *Apache SystemML*, *Caffe*, *Torch* y Navegador Anaconda. Se elige este último por su facilidad de instalar y administrar paquetes, manejo de paquetes en forma relativamente simple y compilación de Python. La Tabla 4 compara las distintas plataformas mencionadas.

El sistema propuesto puede clasificar servicios en redes de próxima generación. Sin embargo, es fundamental aclarar (como se mencionó líneas arriba) que el clasificador forma solo una parte de un sistema que un operador de red puede utilizar para ofrecer servicios. El sistema clasificador de servicios necesita interactuar para conectarse con el resto del sistema del operador, por lo que se deben considerar dos opciones:

1. Reprogramar el sistema propuesto en el idioma del sistema del operador. Esto tiene el inconveniente de requerir la reprogramación de los sistemas utilizados por cada

operador, incluida la nube, lo que no es muy factible (por problemas de mantenimiento o actualización futuros).

2. Incorporar en el sistema propuesto una Interfaz de programación de aplicaciones (API, por las siglas de término en inglés, *Application Programming Interface*) apropiada para permitir la comunicación con el sistema del operador (accesible desde un servidor público o privado). Se debe proporcionar la seguridad necesaria para garantizar que esto solo se emplee de manera autorizada.

Es preferible la segunda opción, ya que los sistemas 5G proporcionan API apropiadas para permitir que un tercero de confianza cree, modifique, elimine y monitoree instancias de los segmentos de red utilizados por el tercero, y para administrar un conjunto de dispositivos o capacidades que incluyen funciones de QoS [22].

Para crear la API en el sistema que se propone, se pueden utilizar diferentes infraestructuras ya existentes, como las que ofrecen *Google*, *Amazon* y *Microsoft*. Asimismo, existen plataformas que facilitan la instalación de una API.

3.7 Conclusiones

En este capítulo se puede concluir que:

- La identificación plena de los servicios 5G/B5G es esencial principalmente porque permite la asignación precisa de recursos *ad hoc* al servicio en el *network slice* por parte del proveedor, de tal suerte que su desempeño sea el idóneo.
- Ante la dificultad de contar con un *dataset* con datos KPI y KQI operativos (de redes 5G operando), se propone la construcción de una base de datos (*dataset*) sintética.
- El sistema clasificador de servicios 5G propuesto, tiene como entrada un vector de características (x) formado por los parámetros de los KPI y KQI de los servicios 5G que se quieren clasificar.

- El etiquetado, división del *dataset* para entrenar, probar y validar el sistema de clasificación propuesto, así como las retroalimentaciones permiten su auto-ajuste en forma dinámica.
- Al aplicar ML se mejora la clasificación de los servicios; lo cual permite que un operador que emplee el sistema propuesto asigne y ajuste los recursos necesarios al ofrecerlos y trabajar en la mejora de la QoS de la red 5G, cumplir con los SLA establecidos y mejorar la percepción y experiencia del servicio recibido por los usuarios.
- Para permitir la comunicación del sistema de clasificación de servicios 5G/B5G que se propone, se hace necesario la incorporación de una API, que interactúe con los sistemas del proveedor de servicios de telecomunicaciones que lo emplee.

En el capítulo 4, se valida el alcance del sistema clasificador de servicios 5G basado en técnicas y algoritmos ML con el empleo de un método de simulación. A través de esta, se analizan las distintas métricas obtenidas (ecuaciones de 1 a 5) y se evalúa el rendimiento del modelo predictivo. Con la intención de conocer si al incorporar los KQI existe una mejora tanto en las métricas resultantes, como en la QoS y en la QoE, se realizan dos simulaciones (la primera con los parámetros de KPI y la segunda incorporando los parámetros de KQI); se comparan los resultados de estas, y así, comprobar el cumplimiento de los objetivos del sistema clasificador de servicios propuesto.

4 CAPÍTULO: VALIDACIÓN DEL SISTEMA PROPUESTO

4.1 Introducción

La red 5G tiene un carácter novedoso, lo que hace necesaria su investigación siendo la simulación uno de los métodos que apoya este proceso. El sistema clasificador de servicios 5G/B5G que se propone, permite mejorar los parámetros de QoS de la red, la QoE percibida por el usuario y el cumplimiento de los SLA, como se definió en el capítulo 3 de este trabajo.

En este capítulo se realiza la validación del sistema propuesto para la clasificación de servicios 5G a partir de sus KPI y KQI y basado en ML. Como método de validación se emplea la simulación, por lo que se parte de plantear el escenario de simulación para posteriormente realizar esta. Con el objetivo de comprobar el desempeño de cada uno de ellos con la base de datos creada, se realizan las simulaciones con algunos algoritmos de SL.

De acuerdo a lo planteado, en el epígrafe 4.3, primeramente, se realizará la simulación con los KPI de los servicios 5G, y posteriormente se consideran e incluyen los KQI. Finalmente, se hace un análisis profundo de los resultados obtenidos en las dos simulaciones para decidir el modelo predictivo que se ajusta mejor a la problemática de clasificar servicios 5G utilizando KPI/KQI.

4.2 Escenario de validación

Resulta imprescindible definir un escenario donde se expliquen las condiciones para la implementación del sistema de clasificación y validación del mismo. El escenario se define por la selección de los elementos necesarios: algoritmo de ML, lenguaje de programación y plataforma de desarrollo, los servicios 5G a clasificar, así como la base de datos (*dataset*) con los parámetros o valores correspondientes a sus KPI y KQI.

Con la idea de analizar si la inclusión de los parámetros KQI adicionalmente a los KPI mejoran la clasificación de los servicios considerados, se realizan dos simulaciones para cada modelo. La primera considera solo los KPI, mientras que la segunda incorpora los KQI.

4.2.1 Selección del algoritmo de ML

En el epígrafe 2.6, se revisaron algunas de las propiedades y características de los algoritmos con la finalidad de ayudar a la elección de uno de ellos para la generación de un modelo predictivo para la implementación del sistema que se propone.

Existen diversos algoritmos de SL que se pueden emplear para la implementación del sistema que se propone. En este trabajo se utilizan los siguientes:

- Árbol de decisión (*Decision tree*).
- Bosque aleatorio (*Random forest*).
- Máquina de soporte vectorial (SVM).
- K-Vecinos más cercanos (KNN).
- Red neuronal multicapa de tipo perceptrón (MLPC, por sus siglas en inglés *Multi-Layer Perceptron Classifier*).

Del análisis de los resultados y de sus métricas de desempeño obtenidos de la simulación del sistema de clasificación con los algoritmos propuestos, se establecerá cuál o cuales de ellos son los que se adaptan mejor.

4.2.2 Selección del lenguaje de programación y de la plataforma de desarrollo

En la selección del lenguaje de programación a emplear se tuvo en consideración, que fuera de código abierto dadas las bondades del mismo, vistas en la sección 3.6 y, adicionalmente, aspectos como la velocidad de procesado, la facilidad de aprendizaje y la comunidad de desarrollo. De acuerdo con lo anterior, en este trabajo se selecciona el lenguaje de programación *Python* el cual, además, es líder en lenguajes de desarrollo de ML y análisis de datos, sobre todo por su simplicidad y facilidad de aprendizaje.

En comparación con otros lenguajes de programación, *Python* es relativamente fácil de aprender, adoptar, adaptar por los programadores y/o principiantes y es un lenguaje gratuito de alto nivel. Contiene librerías específicas que le facilitan el trabajo a los

programadores, por ejemplo: *Scikit-Learn*, que brinda una gama de algoritmos de aprendizaje de ML, técnicas de validación y métricas de evaluación; *NumPy (Numerical Python)*, proporciona potentes estructuras de datos implementando vectores y matrices más rápido, ocupando menor espacio que las listas propias de *Python*; y *Pandas (Panel Data)*, para manipulación y análisis de datos de alto rendimiento.

Cuando se trabaja con el lenguaje *Python* y en una aplicación de ML, muchas son las plataformas en las que se puede desarrollar un proyecto, algunas de las cuales se caracterizan en la Tabla 4. Para el escenario de validación en el cual se va a simular la propuesta de sistema para la clasificación de servicios 5G, se escogió la plataforma navegador Anaconda (*Anaconda Navigator*).

Como se observa en la Tabla 4, Anaconda es conocida como la *suite* más completa de código abierto empleando *Python* para la ciencia de datos, pues abarca una serie de aplicaciones, librerías y conceptos diseñados para este fin. Este navegador permite iniciar aplicaciones y administrar fácilmente paquetes, entornos y canales, sin usar comandos de línea [69].

Anaconda Navigator tiene instalados varios paquetes de entornos de desarrollo integrado (IDE, por las siglas del término en inglés, *Integrated Development Environment*) como *Spyder* y *Jupyter*, que proporcionan servicios integrales al programador.

Algo más que contribuyó a la selección de la plataforma de desarrollo Anaconda es que con ella se puede instalar de forma sencilla la estructura conceptual y tecnológica de soporte definido (*web framework*) *Flask* que, facilitaría la creación de APIs. Esta opción permite conectar el sistema que se propone para la clasificación de servicios 5G con el sistema que utilice el operador.

Tabla 4. Comparativa de algunas plataformas de desarrollo de código abierto [Elaboración propia], [69][70].

Aspecto	TensorFlow	Apache SystemML	Caffe	Torch	Navegador Anaconda
Sistemas operativos	Linux, Windows MacOS, Android, iOS.	Linux, MacOS. Windows.	Linux, MacOS. Windows.	Linux, Android, iOS.	MacOS. Windows. Linux.
Lenguajes de programación	Python, C++, JavaScript, R.	Python, R, Java.	Python.	C++, Python.	Python, R.
Características	Para el cálculo numérico de alto rendimiento. Detecta y descifra patrones. Se construyó en base a facilidad de ejecución y escalabilidad. Permite ser ejecutada en la nube.	Es flexible para el aprendizaje computacional con múltiples modos de ejecución. Posee optimización automática basada en datos y características de clúster para garantizar la eficiencia y escalabilidad.	Se enfoca en redes convolucionales. Soporta tipos de aprendizaje profundo en la clasificación de imágenes y su segmentación. La velocidad de procesamiento es su principal ventaja.	Tiene muchas rutinas para indexar y una increíble interfaz para C. Posee: rutinas de álgebra lineal, red neuronal y modelos basados en la energía, rutinas de optimización numérica y soporte de GPU rápido.	Permite instalar y administrar paquetes, dependencias y entornos de manera sencilla. Posee una gran variedad de aplicaciones relacionadas con ML. Compila Python en código de máquina. Es una <i>suite</i> para la ciencia de datos con Python.

4.2.3 Servicios 5G a clasificar y sus parámetros KPI y KQI

Existen una gran variedad de servicios 5G a ser implementados que tienen lugar dentro de los casos de uso descritos en el capítulo 2. Clasificar todos los servicios desplegados en 5G constituye una tarea ardua, ya que una parte de estos no están aún implementados. Para la validación del sistema que se propone para la clasificación de servicios 5G, se consideran nueve servicios recogidos en el capítulo dos. Estos servicios son:

1. Video UHD transmitido en vivo (*UHD video streaming*).
2. Experiencias inmersivas (*immerse experience*).
3. Vehículos conectados (*connected vehicles*).
4. Salud electrónica (*eHealth*).
5. Automatización de las industrias (*industry automation*).
6. Vigilancia en video (*video surveillance*).
7. Redes inteligentes (*smart grid*).

8. ITS, Sistema de Transporte Inteligente (*Intelligence Transport System*)
9. Vo5G, Voz sobre 5G.

Las redes al estar operando arrojan una inmensa cantidad de datos generados por los servicios que ofrecen. Estos datos son necesarios para, por un lado, obtener estadísticas del uso y funcionamiento de la red, y por otro, lograr la prestación eficiente de los servicios. Dichos proveedores protegen esta información como uno de sus activos comerciales más valiosos que poseen. Debido a esto, y ante la falta de información pública, los grupos de trabajo en tecnologías de redes en 5G, tanto, oficiales como académicos, así como entidades desarrolladoras de aplicaciones y servicios, definen y generan sus propios conjuntos de datos para la investigación [39]. Se debe precisar que se consideraron, dentro de los KPI y KQI de los servicios 5G en los que se simuló su clasificación, aquellos parámetros en los que se encontró mayor información en la bibliografía.

A continuación, se listan los parámetros de los KPI y KQI empleados en la simulación, los valores que toman estos parámetros se recopilan en el ANEXO 1. Parámetros de KPI y KQI de servicios 5G.

Latencia E2E.

1. *Jitter*.
2. Tasa de bits.
3. Tasa de pérdida de paquetes.
4. Velocidad de datos pico para DL
5. Velocidad de datos pico para UL.
6. Movilidad.
7. Confiabilidad del servicio.
8. Disponibilidad del servicio.
9. Tasa de datos experimentada por el usuario para DL. En muchos proyectos este parámetro es considerado un KPI, para la realización de este trabajo se considera un KQI, porque es la velocidad de datos experimentada por el usuario para DL en la

implementación de red y brinda parámetros de calidad desde una perspectiva de usuario.

10. Tasa de datos experimentada por el usuario para UL. En muchos proyectos este parámetro es considerado un KPI, para la realización de este trabajo se considera un KQI, porque es la velocidad de datos experimentada por el usuario para UL en la implementación de red y brinda parámetros de calidad desde una perspectiva de usuario.

11. Tiempo de supervivencia.

12. Tiempo de interrupción.

4.2.4 *Dataset* de parámetros claves de los servicios.

Al analizar detalladamente estándares y una gran variedad de artículos científicos con el objetivo de confeccionar la base de datos que se empleará para validar el sistema que se propone para la clasificación de servicios 5G se encontró que la mayoría de estos servicios no se encuentran estandarizados actualmente, lo que implica que ciertos parámetros claves de desempeño (KPI) y de calidad (KQI) que los distinguen, no estén definidos con exactitud. Esto dificultó la obtención del conjunto de datos y, por ello, se asumieron algunos valores de KPI y KQI, sujetos a errores experimentales, que no afectan la validez del modelo predictivo.

Tal como se indicó en sección 3.3, la base de datos se creó a partir de la información contenida en artículos, estándares y en documentos de proyectos de compañías de telecomunicaciones, referenciados en dicha sección. Recordar que, la base de datos contiene 165 filas y 14 columnas. Las filas (165) corresponden a los valores de los parámetros de los servicios 5G a clasificar y, de las 14 columnas contienen: las 13 primeras los valores de KPI y KQI, mientras que la última columna corresponde a las etiquetas de los servicios 5G. Este *dataset* se puede consultar en el ANEXO 2. Base de datos (*dataset*) creada con valores KPI y KQI de los servicios 5G.

4.3 Validación o comprobación del sistema de clasificación propuesto.

En este epígrafe se describe el proceso de simulación del algoritmo de ML y del modelo predictivo del sistema de clasificación de servicios 5G propuesto en la Figura 21.

Para determinar si la inclusión de KQI mejora el modelo de clasificación de servicios predictivos, se realizan dos simulaciones. La primera considera solo los KPI, mientras que la segunda incorpora los KQI.

- **Escenario**

Primeramente, se explica y se define el escenario y las condiciones utilizadas en ambas simulaciones (que llamaremos Caso 1 y Caso 2). Los elementos necesarios son los algoritmos SML, un lenguaje de programación, una plataforma de desarrollo, los servicios 5G a clasificar y los parámetros de sus KPI y KQI.

Para el escenario de validación y para simular el sistema propuesto, se utilizan los algoritmos SL: Árbol de decisión (DT), Bosque aleatorio (con cinco árboles), Máquina de vectores de soporte (SVM) con un kernel lineal, K-Vecinos más cercanos (KNN, $K = 3$) y *Multi-Layer Perceptron Classifier* (MLPC), usando el lenguaje Python, y la plataforma *Anaconda Navigator* con *Jupyter Notebook* como IDE. Para leer desde este IDE el formato de la base de datos (CSV) se debe indicar la ruta donde esta se encuentra guardada, ya sea local o en la nube. Luego, con el uso de la librería *Pandas*, se puede leer la base de datos como una estructura de datos de dos dimensiones (columnas y filas), en inglés se le conoce como *dataframe*. La función de esta librería que se utiliza para leer la base de datos es *pd.read_csv*, y en ella se especifica la ruta y el nombre del archivo.

Se consideran nueve servicios 5G esenciales a clasificar: transmisión de video de ultra alta definición (UHD), experiencia inmersiva, vehículos conectados, salud electrónica, automatización de la industria, videovigilancia, red inteligente, sistemas de transporte inteligente (ITS) y voz sobre 5G (Vo5G). Los parámetros de KPI seleccionados fueron latencia

E2E, *jitter*, tasa de bits, tasa de pérdida de paquetes, velocidad máxima de datos *DownLink* (DL), velocidad máxima de datos *UpLink* (UL), movilidad y confiabilidad del servicio.

Los parámetros KQI fueron la disponibilidad del servicio, la tasa de datos de la experiencia del usuario DL / UL, el tiempo de supervivencia y el tiempo de interrupción.

Se trabajó en dos casos: En el caso 1, usando solo KPI y en el caso 2, incluyendo los KQI o sea con parámetros KPI y KQI.

4.3.1 CASO 1: Simulación usando solo KPI

4.3.1.1 *Etiquetado de los datos*

En el diagrama a bloques de la Figura 21, el segundo bloque representa el etiquetado de los datos. Para esta simulación, dado que el conjunto de datos se confecciona de forma manual, se procede de igual forma con el etiquetado de los datos; a cada característica (x) se le asigna el servicio 5G (etiqueta y) que le corresponde, como se explicó en el capítulo tres.

Antes de seguir con la simulación hay que verificar que los tipos de datos de los KPI de la base de datos sean numéricos. Esto se debe a que las funciones matemáticas de ML no permiten datos de tipo texto. La librería *Pandas* asigna tipos de datos automáticamente, pero de igual forma se hace necesario comprobar. Para este caso todos los parámetros de KPI son datos de tipo numérico, por lo que no hay que realizar ninguna conversión de los mismos para trabajar sin problemas. En el ANEXO 3. Tipos de datos de los parámetros de KPI y KQI de los servicios 5G, se pueden ver las variables (KPI y KQI) y el tipo de dato que le corresponde a cada una.

4.3.1.2 *División de datos*

El escenario es el descrito en 4.3; el conjunto de datos tiene dimensiones de 165×9 , donde las primeras ocho columnas representaban los KPI y la última contenía las etiquetas de los servicios. Se divide la base de datos en dos partes, donde se utilizó el 80% (132) de los datos (*Xtrain*) para entrenar los algoritmos creados y, una vez entrenados, se generó el modelo

predictivo. El 20% restante (X_{test}) se utilizó para probar el modelo. Una de las librerías que más se emplea en este trabajo es Scikit-Learn, la cual incluye la función *train_test_split*. Esta función permite tomar muestras aleatorias, no en secuencia, sino mezcladas para llevar a cabo la división de los datos. Los parámetros de entrada que se le indican a esta función son: la variable de entrenamiento, la variable de prueba, y la cantidad (expresada en %) de cada variable que se quiere dividir. Se emplea esta función para realizar la división de los datos planteada, que como también se explicó en el capítulo tres genera cuatro nuevas variables: X_{train} , X_{test} , Y_{train} y Y_{test} .

4.3.1.3 Entrenamiento del algoritmo de ML

Una vez divididos los datos se procede a crear los modelos predictivos. Para ello se emplean las funciones de la librería Scikit-Learn. Se usan las siguientes funciones: *DecisionTreeClassifier*, *RandomForestClassifier*, *SVC*, *KNeighborsClassifier* y *MLPClassifier*; para generar un árbol de decisión, un bosque aleatorio (de cinco árboles), una SVM (con un kernel lineal), un clasificador KNN (con $K=3$) y una MLPC, respectivamente.

Una vez creados los modelos para clasificar, se procede a entrenarlos con los datos de X_{train} y Y_{train} . Los modelos pueden ser propensos a desajustarse o sobreajustarse, lo que significa que funcionará perfectamente para los datos de entrenamiento (X_{train}) que ya se conocen, pero su precisión puede ser menor para los nuevos servicios (X_{test}). Según [46], [47], hay dos enfoques posibles para evitar el sobreajuste: aumentar el volumen de la base de datos o reservar datos adicionales dividiendo el conjunto de datos en tres partes (entrenamiento, validación y prueba). Aumentar la cantidad de datos fue difícil porque no había suficientes datos conocidos del servicio 5G; por lo tanto, se reservaron datos adicionales y se aplicó la técnica de validación cruzada de *K-Folds* utilizando $K = 10$ [71] y se obtuvieron los resultados que se muestran en la Tabla 5.

Tabla 5. Resultados de la precisión en la etapa de validación cruzada para la primera simulación (KPI).

Algoritmos de SL	Resultados de la validación cruzada K-Folds (K = 10)
Árbol de decisión	99.23
Bosque aleatorio	99.23
SVM	92.42
KNN	59.83
MLPC	87.08

4.3.1.4 Validación del algoritmo ML y prueba del modelo predictivo

Cabe señalar que todos los datos forman parte del conjunto de datos original, y no constituye tres nuevos conjuntos de datos, es decir se “crea” el conjunto de validación, y se utiliza durante las iteraciones que se hacen en el conjunto de entrenamiento. En el caso que se ocupa, para aplicar la técnica de validación cruzada de K-iteraciones se emplean las funciones *KFold* y *cross_val_score*, de la librería *Scikit Learn*. La función *cross_val_score* evalúa una métrica o puntuación deseada para cada división de los datos, mediante validación cruzada. Es decir, como se tienen 10 subconjuntos, se pudieron tener diez valores de exactitud. Este proceso ayudó a comprobar si el algoritmo de ML se entrenó correctamente o, si el modelo predictivo que se emplea no fue adecuado para resolver el problema de clasificación. Más información de estas funciones o del proceso completo de validación cruzada se puede encontrar en la página oficial de *Scikit Learn* [64].

Para realizar predicciones con el modelo predictivo se emplea la función *predict*. La función de *Scikit Learn* tiene como parámetro de entrada un vector de características de los servicios 5G a clasificar que en este caso es el conjunto de datos de prueba *Xtest*, que se obtuvo en la división del conjunto de datos de entrada. La salida de esta función es el vector *Y* (véase Figura 21), generado por el modelo predictivo. Como se mencionó en el capítulo 3, se deben comprobar las métricas del modelo de ML en relación con los datos de los que ya sabe la

respuesta (comparar Y con Y_{test}) y utilizar así esta prueba como base de precisión predictiva para futuros datos y para validar el modelo predictivo.

4.3.1.5 Validación del modelo predictivo

Para realizar la validación del modelo predictivo se utilizan un grupo de funciones de la librería *Scikit Learn* que ayudan a establecer algunas de las principales métricas de evaluación de las predicciones. Estas funciones son: *confusion_matrix*; permite la visualización de la matriz de confusión generada, y las funciones *accuracy_score*, *precision_score*, *recall_score*, *f1_score* y *matthews_corrcoef* arrojan los valores de las métricas de desempeño.

La Figura 22 muestra las matrices de confusión obtenidas durante el proceso de prueba para cada modelo en la primera simulación, en la que solo se consideran los KPI. La diagonal principal muestra el número de predicciones correctas realizadas por el modelo predictivo. Los valores fuera de la diagonal principal representan predicciones en las que el modelo estaba equivocado.

Al analizar las matrices de confusión reflejadas en la Figura 22 de forma individual, se obtienen las principales métricas para evaluar el rendimiento de los modelos predictivos. Con el objetivo de un mejor entendimiento de esta matriz se ejecutan los códigos de las funciones de *Scikit Learn* descritas (o se utilizan las ecuaciones de la 1 a la 5) para mostrar las distintas métricas obtenidas en la simulación para los servicios analizados. A continuación, se muestra un análisis de los resultados obtenidos en esta simulación para cada modelo de forma individual.

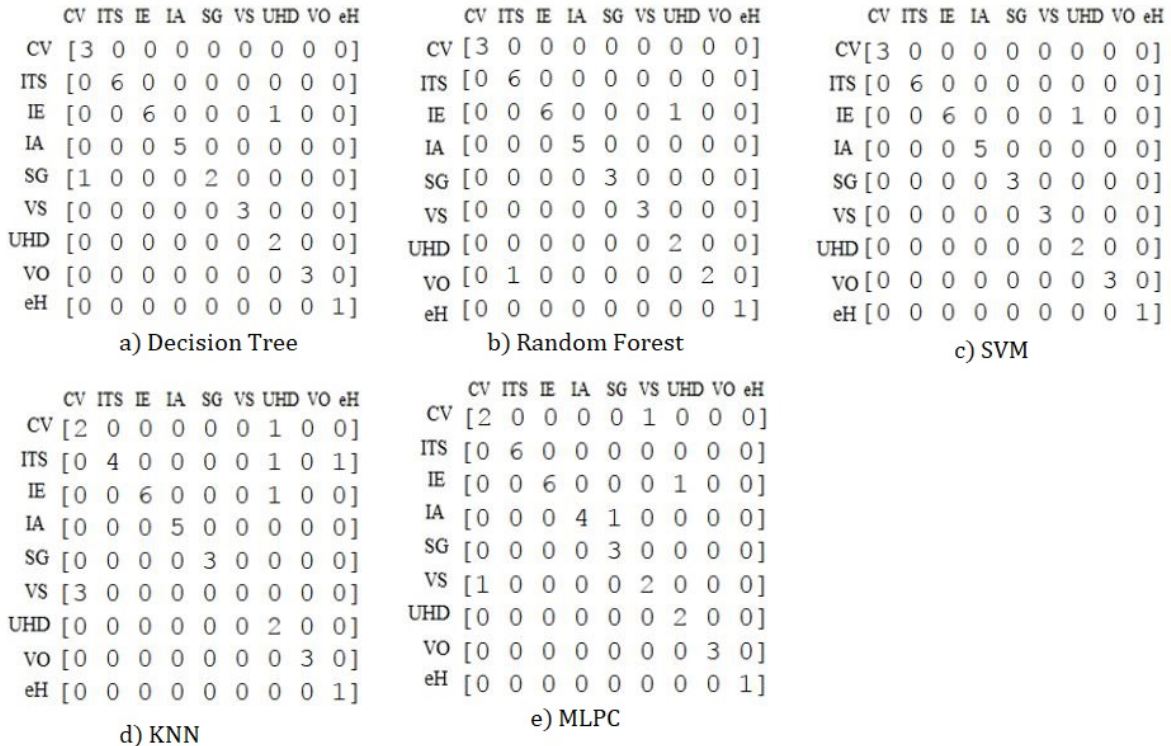


Figura 22. Matrices de confusión de la 1ra simulación (KPI). CV: Connected Vehicles; IE: Immersive Experience; IA: Industry Automation; SG: Smart Grid; UHD: Video Streaming; VS: Video Surveillance; VO: Vo5G; eH: e-health.

Con la ayuda de la Figura 22 inciso a) (*Decision tree*) se puede ver que el algoritmo **árbol de decisión** creado y entrenado con parámetros de KPI confunde un servicio de redes inteligentes (*smart grid*) con uno de vehículos conectados. Esto hace que la precisión y la puntuación F1 al clasificar servicios de vehículos conectados sea del 75% y 85.7%, respectivamente; mientras que la sensibilidad y la puntuación F1 al clasificar servicios de redes inteligentes sea del 66.7% y 80%, respectivamente. También se observa que confunde un servicio de experiencias inmersivas y lo trata como uno de video UHD transmitido en vivo. Esto implica que las métricas de precisión, sensibilidad y puntaje F1 bajen considerablemente a los valores reflejados en la Tabla 6.

Tabla 6. Resultados del modelo árbol de decisión (1ra simulación KPI). Nota: Support indica cantidad.

	precision	recall	f1-score	support
Connected_Vehicles	0.750	1.000	0.857	3
ITS	1.000	1.000	1.000	6
Immerse_Experience	1.000	0.857	0.923	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	0.667	0.800	3
Surveillance	1.000	1.000	1.000	3
UHD_Video_Streaming	0.667	1.000	0.800	2
Vo5G	1.000	1.000	1.000	3
e_Health	1.000	1.000	1.000	1
accuracy			0.939	33
macro avg	0.935	0.947	0.931	33
weighted avg	0.957	0.939	0.940	33

En el caso del algoritmo **bosque aleatorio**, se obtienen métricas bastante similares al caso del árbol de decisión, y en algunas situaciones se equivoca en los mismos servicios; como es el caso de experiencias inmersivas y video UHD transmitido en vivo. Sin embargo, este se equivoca confundiendo servicios de Vo5G con servicios de ITS. Este análisis se puede apreciar en la Figura 22 b). Los valores de precisión, sensibilidad y puntuación f1 se observan en la Tabla 7.

Tabla 7. Resultados del modelo bosque aleatorio (1ra simulación KPI)

	precision	recall	f1-score	support
Connected_Vehicles	1.000	1.000	1.000	3
ITS	0.857	1.000	0.923	6
Immerse_Experience	1.000	0.857	0.923	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	1.000	1.000	3
Surveillance	1.000	1.000	1.000	3
UHD_Video_Streaming	0.667	1.000	0.800	2
Vo5G	1.000	0.667	0.800	3
e_Health	1.000	1.000	1.000	1
accuracy			0.939	33
macro avg	0.947	0.947	0.938	33
weighted avg	0.954	0.939	0.939	33

En la Figura 22 c), se observa la matriz de confusión para el modelo **SVM**. Este modelo solo se equivoca con un servicio de experiencias inmersivas, al catalogarlo como de video UHD transmitido en vivo. Por esto, su exactitud es del 97% y las métricas individuales disminuyen un poco en el ejemplo expuesto, pero sin influir mucho en el resultado final. La Tabla 8 contiene las métricas que se obtuvieron durante la simulación.

Tabla 8. Resultados del modelo SVM (1ra simulación KPI).

	precision	recall	f1-score	support
Connected_Vehicles	1.000	1.000	1.000	3
ITS	1.000	1.000	1.000	6
Immerse_Experience	1.000	0.857	0.923	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	1.000	1.000	3
Surveillance	1.000	1.000	1.000	3
UHD_Video_Streaming	0.667	1.000	0.800	2
Vo5G	1.000	1.000	1.000	3
e_Health	1.000	1.000	1.000	1
accuracy			0.970	33
macro avg	0.963	0.984	0.969	33
weighted avg	0.980	0.970	0.972	33

Al observar la matriz de confusión de la Figura 22 d), se constata de la cantidad de errores cometidos por el modelo KNN. Se tiene una exactitud del 78.8% (ver Tabla 9), y las demás métricas con valores muy similares a este porcentaje. El modelo confunde servicios de vehículos conectados, ITS y experiencias inmersivas, clasificándolos como de video UHD transmitido en vivo. Además, los tres servicios de videovigilancia los confunde con vehículos conectados, así como uno de ITS como que lo clasifica como de *eHealth*.

Tabla 9. Resultados del modelo KNN (1ra simulación KPI).

	precision	recall	f1-score	support
Connected_Vehicles	0.400	0.667	0.500	3
ITS	1.000	0.667	0.800	6
Immerse_Experience	1.000	0.857	0.923	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	1.000	1.000	3
Surveillance	0.000	0.000	0.000	3
UHD_Video_Streaming	0.400	1.000	0.571	2
Vo5G	1.000	1.000	1.000	3
e_Health	0.500	1.000	0.667	1
accuracy			0.788	33
macro avg	0.700	0.799	0.718	33
weighted avg	0.803	0.788	0.775	33

Si se observa la matriz de confusión de la Figura 22 e), es posible ver de igual manera que en el modelo anterior, algunas irregularidades. El modelo presentó una exactitud del 87.9%, ya que tuvo muchas equivocaciones al clasificar servicios (ver Tabla 10), como por ejemplo de vehículos conectados, experiencias inmersivas, videovigilancia y video UHD transmitido en vivo.

Tabla 10. Resultados del modelo de MLPC (1ra simulación KPI).

	precision	recall	f1-score	support
Connected_Vehicles	0.500	0.667	0.571	3
ITS	1.000	1.000	1.000	6
Immerse_Experience	1.000	0.857	0.923	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	1.000	1.000	3
Surveillance	0.500	0.333	0.400	3
UHD_Video_Streaming	0.667	1.000	0.800	2
Vo5G	1.000	1.000	1.000	3
e_Health	1.000	1.000	1.000	1
accuracy			0.879	33
macro avg	0.852	0.873	0.855	33
weighted avg	0.889	0.879	0.878	33

La Tabla 11 muestra un resumen de las métricas obtenidas de las matrices de confusión de la Figura 22 y aplicar las ecuaciones (1) a (5) para evaluar el desempeño del modelo predictivo.

Tabla 11. Métricas resultado del modelo para la primera simulación (KPI)

Algoritmo SL	Exactitud (%)	Precisión Macro (%)	Sensibilidad Macro (%)	F1-Score Macro (%)	MCC (%)
DT	93.9	93.5	94.7	93.1	93.19
RF	93.9	94.7	94.7	93.8	93.17
SVM	96.9	96.3	98.4	96.9	96.6
KNN	76.8	70	79.9	71.8	76.89
MLPC	87.8	82.4	85.1	82.7	86.58

Al terminar la primera simulación se puede concluir que, los mejores modelos predictivos son los generados al entrenar el árbol de decisión, el bosque aleatorio y la SVM. Sin embargo, el objetivo principal que se persigue es comprobar, que al incluir los parámetros de KQI para entrenar estos mismos algoritmos de SL, aumenten las métricas de rendimiento. Por tanto, se debe realizar la segunda simulación para poder dar conclusiones generales.

4.4 CASO 2: Simulación con la incorporación de los KQI

En esta simulación se repitió el procedimiento, siendo la diferencia respecto al CASO 1, la incorporación de los parámetros de calidad de usuario (KQI) a la base de datos en formato CSV para entrenar el algoritmo de ML. Esta es una de las acciones más complicadas (y más importante), pues en la actualidad no hay muchos estándares que reflejen estos parámetros.

Se introdujeron cinco KQI a la base de datos, todos de tipo de dato numérico; por lo que no representa un problema para el algoritmo de ML. Los parámetros de los KQI que se consideraron son los que se listan a continuación y se muestran en el ANEXO 1. Parámetros

de KPI y KQI de servicios 5G, y los valores de estos, que se encuentran almacenados en la base de datos se muestran en el ANEXO 2. Base de datos (*dataset*) creada con valores KPI y KQI de los servicios 5G.

1. Disponibilidad del servicio (*service availability*).
2. Tiempo de supervivencia (*survival time*).
3. Tasa de datos de experiencia de usuario (*user experience data rate*) para DL.
4. Tasa de datos de experiencia de usuario (*user experience data rate*) para UL.
5. Tiempo de interrupción (*interruption time*).

Se mantiene una base de datos que contenía 165 filas, con cinco columnas adicionales correspondientes a los parámetros de KQI, esto con el objetivo de mejorar la clasificación de servicios 5G. Se dividen los datos de igual forma, pero en este caso, la variable independiente (las características de los servicios 5G) es una matriz de tamaño 120 x 13 (120 filas, que se corresponden con los valores de los parámetros de KPI y KQI de los servicios 5G a clasificar y 13 columnas, que contienen los KPI y KQI, considerados en esta simulación).

Se usan las mismas funciones para crear y entrenar el algoritmo de ML, lo que da como resultado los mismos algoritmos ML. Esto permite verificar si al incluir los KQI, el modelo predictivo clasifica servicios con mayores porcentajes en las métricas que los que se obtienen cuando solo se consideran los KPI (CASO 1). Asimismo, se utiliza de nuevo la técnica de validación cruzada de *K-Folds* con $K = 10$ [71] para validar el algoritmo ML y los resultados obtenidos se muestran en la Tabla 12.

Tabla 12. Resultados de la precisión en la etapa de validación cruzada para la segunda simulación (KPI+KQI).

Algoritmos de SL	Resultados de la validación cruzada K-Folds (K = 10)
Árbol de decisión	97.69
Bosque aleatorio	98.52
SVM	91.59
KNN	83.35
MLPC	90.11

La Figura 23 muestra las matrices de confusión obtenidas para los cinco modelos en esta segunda simulación.

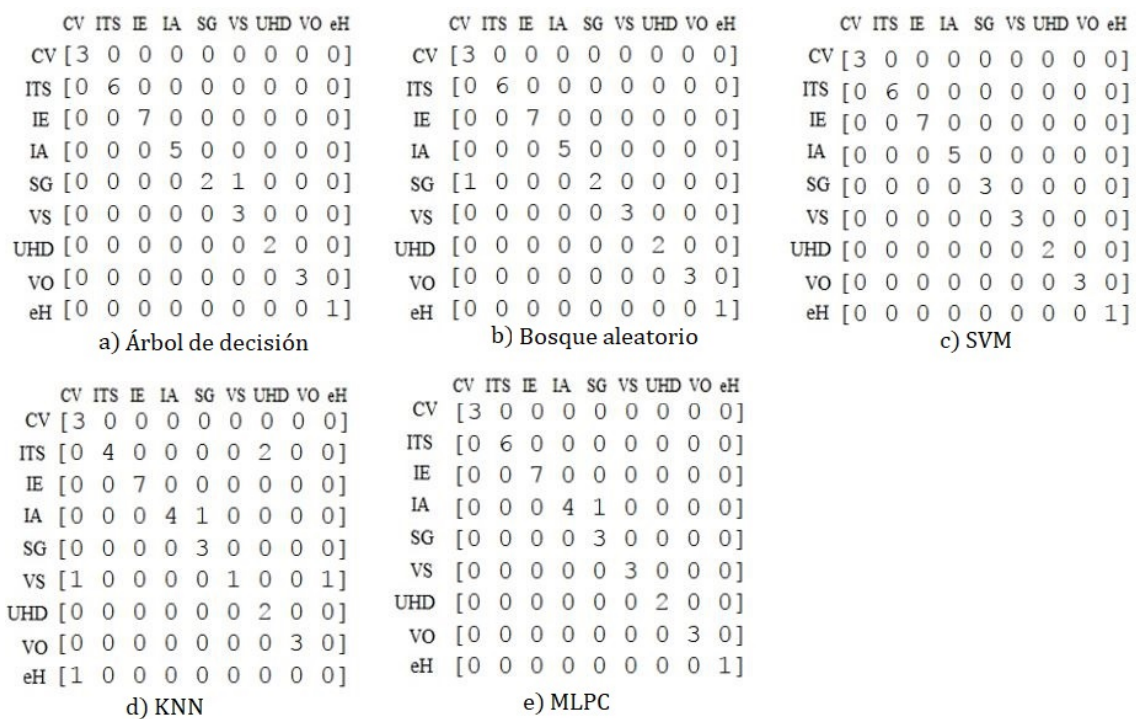


Figura 23. Matrices de confusión de la 2da simulación (KPI+KQI). CV: Connected Vehicles; IE: Immersive Experience; IA: Industry Automation; SG: Smart Grid; UHD: Video Streaming; VS: Video Surveillance; VO: Vo5G; eH: e-health.

Para realizar la predicción y de validar el modelo predictivo, se emplearon las funciones de *Scikit Learn* antes explicadas y se procede de igual forma que en la simulación anterior. Los resultados de manera independiente fueron los siguientes:

En este CASO 2, simulación con el modelo de **árbol de decisión** (ver Figura 23 inciso a), al incluir los KQI se obtiene un 97% de exactitud como se muestra en la siguiente Tabla 13. En la matriz de confusión a) de la Figura 23, se puede distinguir que solo confunde un modelo de redes inteligentes con uno de videovigilancia.

Tabla 13. Resultados del modelo árbol de decisión (2da simulación KPI + KQI).

	precision	recall	f1-score	support
Connected_Vehicles	1.000	1.000	1.000	3
ITS	1.000	1.000	1.000	6
Immerse_Experience	1.000	1.000	1.000	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	0.667	0.800	3
Surveillance	0.750	1.000	0.857	3
UHD_Video_Streaming	1.000	1.000	1.000	2
Vo5G	1.000	1.000	1.000	3
e_Health	1.000	1.000	1.000	1
accuracy			0.970	33
macro avg	0.972	0.963	0.962	33
weighted avg	0.977	0.970	0.969	33

Para modelo de **bosque aleatorio** (ver Figura 23 b), el valor de exactitud para esta segunda simulación fue de 97%, y además se puede observar Tabla 14 que las demás métricas coinciden con las del árbol de decisión de la Tabla 13. En la matriz de confusión (Inciso b, de la Figura 23) se puede observar que confunde un servicio de vehículos conectados con uno de redes inteligentes.

Tabla 14. Resultados del modelo de bosque aleatorio (2da simulación).

	precision	recall	f1-score	support
Connected_Vehicles	0.750	1.000	0.857	3
ITS	1.000	1.000	1.000	6
Immerse_Experience	1.000	1.000	1.000	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	0.667	0.800	3
Surveillance	1.000	1.000	1.000	3
UHD_Video_Streaming	1.000	1.000	1.000	2
Vo5G	1.000	1.000	1.000	3
e_Health	1.000	1.000	1.000	1
accuracy			0.970	33
macro avg	0.972	0.963	0.962	33
weighted avg	0.977	0.970	0.969	33

Observando la matriz de confusión Figura 23 c) para el modelo de **SVM** se extrae que no se equivocó, clasificó bien todos los servicios. Esto se puede apreciar también en la Tabla 15, donde todas sus métricas tienen valor de 100%.

Tabla 15. Resultados del modelo de SVM (2da simulación).

	precision	recall	f1-score	support
Connected_Vehicles	1.000	1.000	1.000	3
ITS	1.000	1.000	1.000	6
Immerse_Experience	1.000	1.000	1.000	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	1.000	1.000	3
Surveillance	1.000	1.000	1.000	3
UHD_Video_Streaming	1.000	1.000	1.000	2
Vo5G	1.000	1.000	1.000	3
e_Health	1.000	1.000	1.000	1
accuracy			1.000	33
macro avg	1.000	1.000	1.000	33
weighted avg	1.000	1.000	1.000	33

Al observar los resultados de la matriz de confusión correspondiente a k-Vecinos Cercanos KNN inciso d) de la Figura 23, se detectan algunos errores. Por ejemplo, el modelo confunde los servicios de videovigilancia con eHealth y vehículos conectados; de automatización de

las industrias con redes inteligentes; de ITS de video UHD transmitido en vivo. Todas estas equivocaciones se traducen en bajos porcentajes en las métricas de rendimiento del modelo, tal como se aprecia en la Tabla 16.

Tabla 16. Resultados del modelo KNN (2da simulación).

	precision	recall	f1-score	support
Connected_Vehicles	0.600	1.000	0.750	3
ITS	1.000	0.667	0.800	6
Immerse_Experience	1.000	1.000	1.000	7
Industry_Automation	1.000	0.800	0.889	5
Smart_Grid	0.750	1.000	0.857	3
Surveillance	1.000	0.333	0.500	3
UHD_Video_Streaming	0.500	1.000	0.667	2
Vo5G	1.000	1.000	1.000	3
e_Health	0.000	0.000	0.000	1
accuracy			0.818	33
macro avg	0.761	0.756	0.718	33
weighted avg	0.880	0.818	0.815	33

En el último algoritmo considerado Figura 23 inciso e) el modelo de la MLPC, se arrojaron los resultados de las métricas de rendimiento que se muestran en la Tabla 17, donde se destaca un 97% de exactitud. Como se puede ver en la matriz de confusión Figura 23 e) el modelo solo se equivoca en un servicio, en el de automatización de las industrias con videovigilancia, lo que implica el buen resultado obtenido.

Tabla 17. Resultados del modelo MLPC (2da simulación).

	precision	recall	f1-score	support
Connected_Vehicles	1.000	1.000	1.000	3
ITS	1.000	1.000	1.000	6
Immerse_Experience	1.000	1.000	1.000	7
Industry_Automation	1.000	1.000	1.000	5
Smart_Grid	1.000	1.000	1.000	3
Surveillance	1.000	0.667	0.800	3
UHD_Video_Streaming	1.000	1.000	1.000	2
Vo5G	0.750	1.000	0.857	3
e_Health	1.000	1.000	1.000	1
accuracy			0.970	33
macro avg	0.972	0.963	0.962	33
weighted avg	0.977	0.970	0.969	33

El resumen de las métricas de desempeño para el modelo predictivo basado en esta segunda simulación (CASO 2) desplegadas en las matrices de confusión de la Figura 23 se muestra en la Tabla 18.

Tabla 18. Métricas resultado del modelo para la segunda simulación (KPI+KQI)

Algoritmo SL	Exactitud (%)	Precisión Macro (%)	Sensibilidad Macro (%)	F1-Score Macro (%)	MCC (%)
DT	96.9	97.2	96.3	96.2	96.6
RF	96.9	97.2	96.3	96.2	96.6
SVM	100	100	100	100	100
KNN	81.8	76.1	75.6	71.8	79.8
MLPC	93.9	97.2	97.8	97.2	93.2

De la Tabla 18, es posible saber que el modelo KNN no se aplica a nuestro problema porque presenta una precisión inadecuada. Además, se observa que los otros modelos incrementaron sus métricas en esta segunda simulación, y las mejores métricas obtenidas son Árbol de decisión (DT), Bosque aleatorio (RF) y máquina de soporte vectorial (SVM).

Para verificar si el modelo predictivo era satisfactorio, se creó una función para comparar la precisión obtenida en la etapa de validación cruzada versus la precisión de la etapa de prueba. Se considera aceptable el modelo si la diferencia no supera el 5%. El resultado obtenido para el SVM tuvo una diferencia de 8.41%, por lo que se concluye que este modelo puede estar sobreajustado. El resultado obtenido tuvo una diferencia de 0,69% y 1,62% en el árbol de decisión y el bosque aleatorio. Este resultado significa que el modelo predictivo generado por los algoritmos de árbol de decisión y bosque aleatorio no se sobreajusta.

Si el modelo predictivo está sobreajustado, se elige la tercera opción, por ejemplo, hacer un Bosque Aleatorio con profundidad máxima.

Las Figura 24 y Figura 25 muestran los esquemas de uno de los árboles en el Bosque Aleatorio en cada simulación. En Figura 24 se puede apreciar los KPI que utiliza el árbol en la primera simulación para clasificar un servicio 5G.

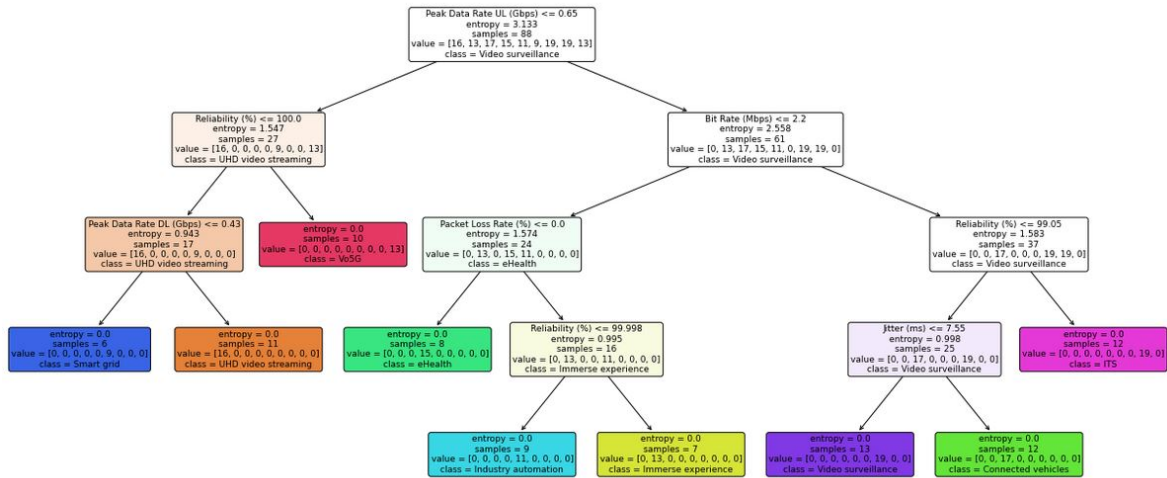


Figura 24. Esquema de un árbol de decisión del bosque aleatorio para la primera simulación (KPI).

Este es un ejemplo de un Árbol de Decisión del Bosque Aleatorio creado. Se observa que tiene una profundidad de 4 nodos para llegar al valor de la clasificación esperado. Para realizar la clasificación de los servicios, el árbol usa los KPI que “estima conveniente”, atendiendo a la estadística de los datos en la base de datos con que se entrenó. Se puede ver cómo va cambiando la tonalidad de color, esto expresa como se va llevado a cabo la clasificación de un servicio. Asimismo, se puede observar como el valor de entropía en el nodo principal es de 3.133 y va disminuyendo hasta llegar a casi cero, lo que implica que se clasificó el servicio. El árbol va identificando un servicio a medida que va recorriendo los nodos, y sabe que cantidad de muestras pertenecen a cada clase (indicado por “value”) donde cada número corresponde a la cantidad de ejemplos de entrenamiento de un servicio determinado. Por ejemplo, hay 16 servicios de UHD Video *streaming*, 13 de Immerse Experience, etc., esto por supuesto en el primer nodo, poco a poco van disminuyendo).

Ahora, en este árbol específicamente usa el KPI de tasa de velocidad pico UL como regla a comparar si es menor o igual a 0.65 Gbps en el nodo principal. Si el servicio que se vaya a clasificar presenta una tasa de velocidad pico UL menor o igual a 0.65 Gbps, se va por la

rama izquierda, la regla a emplear es comparar con el valor de Confiabilidad de 100%. Si la tasa de velocidad pico es mayor a 0.65 Gbps entonces es por la rama derecha, y la regla a aplicar es comparar utilizando el KPI de Tasa de bits (Bit Rate) con un valor de 2.2 Mbps. El servicio sigue recorriendo el camino que se corresponda con sus características que lo determinan, hasta llegar al nodo que le otorga la clase a la cuál pertenece (clasificación). En la segunda simulación (Figura 25), el mismo árbol incorpora KQI para mejorar su clasificación y obtener mejores métricas.

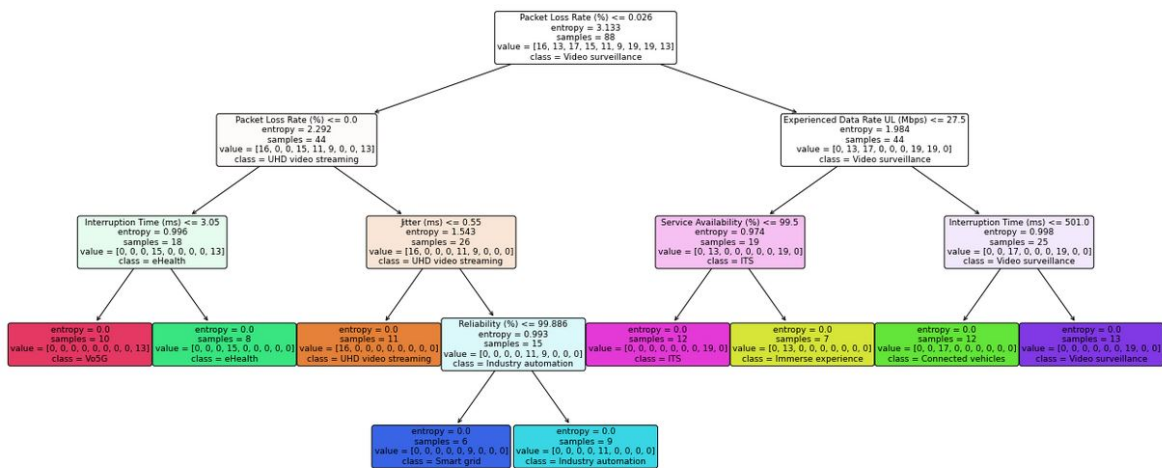


Figura 25. Esquema de un árbol de decisión del bosque aleatorio para la segunda simulación (KPI+KQI).

Al observar un árbol de la segunda simulación, se puede destacar la sustitución de algunos KQI por KPI que estaban en el árbol anterior. Este árbol presenta las mismas características que el de la primera simulación, se puede distinguir, por ejemplo, la misma cantidad de nodos. Sin embargo, este usa como primera regla comparar usando el KPI tasa de pérdida de paquetes con el valor de 0.026%. Si es mayor que este valor entonces usa una nueva regla. Se compara usando el KQI tasa de velocidad de experiencia de usuario UL con 27.5 Mbps, en caso contrario mantiene la regla inicial, solo que cambiando el valor a comparar con 0.0% (recordar que en términos de pérdida de paquetes puede haber valores de 0.0%).

Como era de esperar, cuando se incorporaron los parámetros KQI para clasificar los servicios 5G, el modelo predictivo aprendió a clasificar los servicios de manera más eficaz.

La Figura 26 muestra los resultados promedio en términos de las métricas de evaluación obtenidas por el modelo *Random Forest* para ambas simulaciones. Se observa que hubo incrementos del 3% en exactitud, 2.5% en precisión, 1.6% en sensibilidad, 2.4% en puntaje F1 y 3.4% en MCC.

Los bajos porcentajes en los resultados surgen de la pequeña cantidad de datos disponibles para la simulación. Con un aumento en la cantidad de valores en la base de datos, el algoritmo ML tendría más datos de los que aprender y más datos para clasificar, lo que significa que los porcentajes para el modelo predictivo también aumentarían. Todas estas métricas representan aspectos del desempeño del modelo predictivo del sistema de clasificación de servicios 5G propuesto. Dado que estas métricas se incrementaron, el rendimiento del sistema propuesto también aumentó, lo que significa que se produjo una clasificación de servicios más eficaz cuando se consideraron tanto los KPI como los KQI.

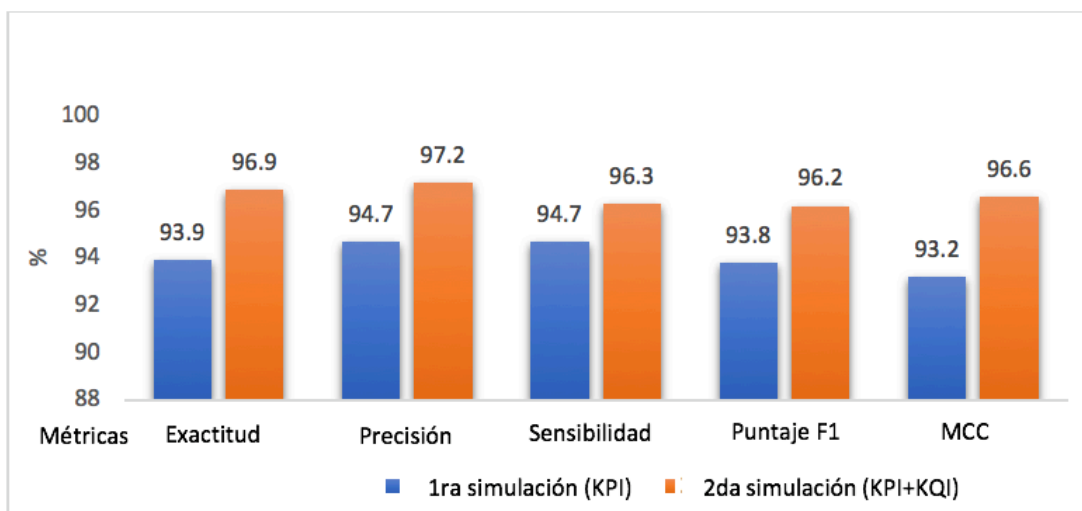


Figura 26. Comparación de los resultados obtenidos por el modelo *Random Forest* para ambas simulaciones.

4.5 Valoración de los resultados

A lo largo de este trabajo se ha planteado que el objetivo de proponer un sistema para clasificar servicios 5G empleando ML, basado tanto en KPI, como en KQI, es mejorar la clasificación de los servicios y, con ello, que el operador asigne los recursos necesarios para optimizar la QoS y la QoE, en particular esta última al incluir los KQI (CASO 2). Las Tabla 11 y Tabla 18 reflejan los resultados obtenidos en las simulaciones.

De la primera simulación, considerando solo los KPI, se puede concluir que el modelo predictivo no aprendió bien a clasificar servicios de experiencias inmersivas (*immerse experience*) ya que en los cinco algoritmos tiene al menos un error y en los cinco eventos se confunde con servicios de video UHD transmitido en vivo, esto se debe, por presentar ambos servicios, características parecidas. Sin embargo, los servicios UHD si los clasifica correctamente, con ninguno de los algoritmos se confunde. Esto se puede ver en las matrices de confusión de la Figura 22. También se puede apreciar en la Figura 22 inciso d) (KNN) los tres servicios de videovigilancia (VS) los confunde con vehículos conectados (CV), en general el algoritmo KNN es el que tiene mayores confusiones al clasificar servicios (con siete para el CASO 1); el modelo predictivo (utilizando el algoritmo de MLPC) confundió cuatro servicios: de vehículos conectados (CV) con videovigilancia (VS) y viceversa, el ya mencionado de experiencia inmersiva con video UHD transmitido en vivo, así como el IA automatización de la industria con redes inteligentes (SG-smart grid) por presentar características muy parecidas, ver Figura 22 e).

De la segunda simulación (CASO 2), considerando los KPI y los KQI, se puede distinguir que el modelo es capaz de clasificar los servicios de experiencias inmersivas, ya que en las matrices de confusión de la Figura 23 se incorporan a la diagonal principal los siete servicios de este tipo. Es decir, el modelo ya clasifica bien los servicios de experiencias inmersivas, no los confunde con los de video UHD transmitido en vivo, por esta razón se obtiene un aumento bastante considerable de las métricas de evaluación del modelo predictivo, lo que

se puede apreciar en la Tabla 18. En general, al algoritmo que más se confunde al clasificar servicios es KNN con seis casos.

Se consideran cumplidos los objetivos propuestos para estas simulaciones. Como se esperaba, con la incorporación de los parámetros de KQI para clasificar servicios 5G el modelo predictivo aprendió a clasificar mejor los servicios. En la Tabla 19 se pueden ver los promedios de las métricas de evaluación de una simulación respecto a la otra. Se aprecia un aumento de un 3.0% en la exactitud, 2.5% en la precisión, 1.6% para la sensibilidad, 2.4% para el puntaje F1 y 3.4% para MCC.

Tabla 19. Promedios de las métricas de evaluación en ambos casos de simulación

[Elaboración propia].

Métricas Simulación	Exactitud (%)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	MCC (%)
Caso 1 (KPI)	93.9	94.7	94.7	93.8	93.2
Caso 2 (KPI + KQI)	96.9	97.2	96.3	96.2	96.6

Algunos porcentajes bajos en los resultados son productos a la cantidad de (pocos) datos que se dispone para la simulación. Con el aumento de la cantidad de valores en la base de datos, el algoritmo de ML tendría más datos para aprender, y más datos para clasificar, lo que implica que los porcentajes de las métricas de evaluación del modelo predictivo también aumentaría. Al final, todas estas métricas se traducen en el desempeño del modelo predictivo del sistema clasificador de servicios 5G que se propone, y si aumentan, el sistema que se propone también tiende a aumentar su desempeño con una clasificación de servicios más eficaz cuando se consideran tanto los KPI como los KQI.

4.6 Conclusiones del capítulo

Para la validación del sistema clasificador de servicios 5G que se propone, se construyó un escenario de validación para el cuál se seleccionaron cinco algoritmos de ML, los parámetros de KPI y KQI a emplear y los servicios 5G a clasificar, entre otros. Por lo tanto:

- Fue posible construir un escenario de simulación para validar el sistema que se propone para la clasificación de servicios 5G. En dicho escenario se utilizó: Cinco algoritmos de ML de aprendizaje supervisado, lenguaje de programación *Python*, Anaconda como plataforma de desarrollo, nueve servicios genéricos a clasificar y una base de datos con formato CSV; donde se encuentran los valores de los parámetros KPI y KQI de dichos servicios.
- Los resultados obtenidos para las simulaciones del modelo predictivo al clasificar servicios 5G, permite observar: primero con los KPI y luego con la incorporación de los KQI; que con la inclusión de estos últimos se obtiene una mejor clasificación de los servicios y, con ello, el proveedor puede mejorar la QoS, la QoE y el cumplimiento de los SLA al asignar recursos de red *ad hoc* a los *network slices*.
- Por lo antes dicho se considera validado el sistema que se propone para la clasificación de servicios 5G empleando ML y basado en los KPI y KQI de los servicios.

5 CONCLUSIONES

Las redes móviles 5G significan una revolución en las comunicaciones que están impactando en la vida de los seres humanos. Al día de hoy, se presenta como novedosa, ya que apenas se encuentra en fase de implementación en el mundo; por lo que se requiere profundizar en el estudio de este tema.

La principal meta de este trabajo fue comprobar la hipótesis de que al considerar los parámetros de calidad (KQI) además de los tradicionales parámetros de desempeño (KPI), se produciría una mejor identificación (mediante clasificación) de los servicios 5G solicitados. Esto se logró con el desarrollo de un sistema de clasificación de los servicios 5G, que utiliza técnicas de ML. En este sentido se verificó la hipótesis planteada y se cumplió con el objetivo principal propuesto. En consecuencia, los proveedores pueden asignar recursos de manera óptima con una gestión de QoS adecuada.

En este trabajo se ha propuesto un sistema de clasificación de servicios en redes de nueva generación basado en ML. El modelo predictivo es un bloque fundamental del sistema clasificador de servicios propuesto, que se encarga de clasificar los servicios 5G. La principal limitación del proyecto fue no tener un conjunto de datos operativos reales 5G. Fue necesario crear un conjunto de datos que contenga parámetros KPI/KQI extraídos de documentos y proyectos de estándares para clasificar los servicios 5G.

El algoritmo de SL generó un modelo predictivo entrenado y validado utilizando los parámetros KPI y KQI para clasificar cada servicio. Con el objetivo de verificar si la inclusión de los parámetros KQI tendría un efecto positivo en el desempeño del modelo y mejorarían la clasificación de los servicios, se establecieron dos fases; en la primera fase, el modelo predictivo clasificó los servicios basándose exclusivamente en los parámetros de desempeño KPI. En la segunda fase, aplicando ambos parámetros (KPI y KQI). Las simulaciones se implementaron empleando cinco algoritmos de SL diferentes (*Decision Tree*, *Random Forest*, *SVM*, *KNN* y *MLPC*) y se validaron los resultados con la técnica de

validación cruzada K-Folds. Se demostró que estos permiten una mejor predicción para clasificar los servicios.

El análisis de los resultados producidos por las matrices de confusión y la aplicación de ecuaciones para evaluar el desempeño indica que es posible comparar los algoritmos de ML propuestos. Además, al comparar los resultados de las simulaciones de las dos propuestas éstos mostraron similitudes; tanto las clasificaciones de servicios por árboles de decisión como por bosques aleatorios resultaron ser los mejores enfoques.

La incorporación de KQI permitió mejoras de 3% en exactitud (*Accuracy*) y 3.41% en MCC para la clasificación de servicios utilizando un algoritmo de bosque aleatorio, como se muestra en la Tabla 19. El objetivo era demostrar que incluir KQI además de KPI en la clasificación de servicios mejoraría la identificación de los servicios. Esta idea se apoyó mediante técnicas de aprendizaje automático para resolver una red de telecomunicaciones de nueva generación. De acuerdo a los resultados obtenidos resultó satisfactorio.

El sistema de clasificación desarrollado permitirá a los proveedores de servicios asignar recursos *ad hoc* para el servicio, ya que se demostró con la realización de esta tesis que el uso conjunto de los parámetros KPI y KQI es crucial para identificar y caracterizar cada servicio solicitado por el UE. Esta es una tarea crucial durante la selección de los segmentos de red (*Network Slicing*) en redes de nueva generación (5G/B5G), ya que implícitamente, un buen esquema de clasificación a través de la gestión de redes y servicios, puede mejorar la QoS del servicio el cumplimiento del SLA y, en consecuencia, una mejor QoE percibida por los usuarios.

No resulta sencillo comparar los resultados obtenidos en este trabajo con los resultados desarrollados por otros colegas, hacer una comparación directa entre las dos propuestas se dificulta dado que las características o atributos difieren. El grupo de investigación de aprendizaje automático de red (NMLRG) [40], presentó resultados de clasificación de servicios en redes 5G, en estos proyectos solo se consideran los parámetros KPI, los valores involucrados son subjetivos (p. ej. pequeños, altos, etc.). Sin embargo, hay coincidencia en

los objetivos de lo que se pretende, identificar los servicios y promover una sintonización eficiente de los recursos de red. Respecto a los resultados, hay coincidencia en ambos trabajos ya que las mejores métricas del comportamiento de los algoritmos utilizados para la clasificación fueron mayores para: árbol de decisión y bosques aleatorios.

El sistema predictivo desarrollado para la clasificación de servicios en redes 5G/B5G opera primero fuera de línea. Una vez que el modelo predictivo ha sido validado y puede aprender a clasificar los servicios de manera efectiva con pocos errores pasaría a la fase de implementación. Se propone que, en la siguiente fase, los operadores de red implementen el sistema en línea; sería mediante la instalación de una API en la RAN que clasifique los servicios nuevos solicitados por los UE, lo anterior permitiría presentar un servicio clasificado, y conocimiento pleno de los requerimientos técnicos, esta es información valiosa para el proveedor de recursos de telecomunicaciones y creación del *network slice ad hoc* al servicio.

Ante la carencia de una base de datos con valores de desempeño operativos, valores reales de funcionamiento de redes 5G, se optó por crear una base de datos “sintética” tal como se explicó, extraída de estándares y de documentos de instituciones y empresas de telecomunicaciones. Afortunadamente, ya están operando varias redes y se espera que pronto se pueda contar con información del desempeño del funcionamiento de ellas. Por lo que, se propone que para simulaciones futuras se utilicen un conjunto de datos (*dataset*) con valores operativos reales para los parámetros KPI y KQI de las redes 5G/B5G para caracterizar mejor el rendimiento de la red. La base de datos creada, esta a disposición de quien la requiera en el sitio de Zenodo.org (<https://zenodo.org/record/4779074#.YK8rd5MzbOQ>, doi:10.5281/zenodo.4779074)

6 RECOMENDACIONES y TRABAJO FUTURO

Con el estudio realizado y con la lectura de una gran cantidad de información proveniente de entidades gubernamentales, de fabricantes y proveedores de servicios e infraestructura de redes de comunicaciones, es evidente que las redes de 5G presentan en sus casos de uso, un gran salto tecnológico en cuestiones de velocidad en movilidad (mayores que 500 Km/h), y ultra baja latencia (en niveles de 1 ms), y en tasa de datos pico (hasta decenas de Gbps) y anchura de banda de 100 Mbps. Asimismo, el surgimiento de aplicaciones y servicios tecnológicamente convergentes que son soportados por estas redes, donde sus requerimientos de gran ancho de banda, de bajas latencias hacen que su identificación sea crucial, es aquí donde hay convergencia con la tecnología de inteligencia artificial para soportar esta clasificación.

La capacidad de conocer la relación servicios-red es crítica en 5G y en las redes de nueva generación como 6G, donde se ha planteado, p. ej., manejar ultra bajas latencias (1 microsegundo), y velocidades de Tera bits por segundo, eso hace más exigente el conocimiento y análisis de los servicios y los tráfico a través de la red, y permitir acciones como realizar e implementar *networks slicing* y gestión automatizada para evitar la violación de los SLA.

Este software trabajará en el nivel de servicio y permitirá conocer mejor los servicios y aplicaciones, pudiendo ser de tráfico IP en tiempo real. Este conocimiento permitirá al operador distinguir diferentes tipos de tráfico que circulan en la red y gestionar arreglos de los servicios y aplicaciones solicitados por los usuarios de 5G.

Debido a que la clasificación de los servicios en combinación con arquitecturas avanzadas corresponde a gestiones de operación de la red, se propone, profundizar en trabajos de inspección profunda de paquetes de información de tráfico de las aplicaciones, en particular se recomienda:

- Trabajar con valores reales de parámetros de KPI y KQI, que resulten de la operación de las redes 5G. Esto conducirá a caracterizar mejor el desempeño de las redes.
- Realimentar la base de datos con los parámetros de KPI y KQI de cada servicio clasificado, con el objetivo de robustecer el modelo predictivo que clasifica los servicios 5G. Esto permitirá que los servicios sean clasificados en forma más precisa, ya que el modelo predictivo cada vez será capaz de aprender a clasificar nuevos servicios.
- Emplear el sistema propuesto en este trabajo para crear los formatos generales (se conocen como *templates*) para los SLA de cada servicio 5G, lo que ayudará a asignar los *network slices* y mejorar la gestión de la red con la asignación de los recursos necesarios para garantizar una mejor QoS y QoE que lleven al cumplimiento de los SLA.
- Profundizar en la obtención y establecimiento de valores umbrales de los indicadores claves de calidad (KQI), ya que en la actualidad la bibliografía respecto al tema no abunda mucho sobre estos.
- Trabajar en el seguimiento del cumplimiento de los SLA (gestión de monitorización), vigilando la no violación del throughput, y en consecuencia la mejora del QoE y satisfacción del cliente.

7 REFERENCIAS BIBLIOGRÁFICAS

- [1] ITU-R M.2083-0, “IMT Vision - Framework and overall objectives of the future development of IMT for 2020 and beyond,” 2015. [Online]. Available: https://www.itu.int/dms_pubrec/itu-r/rec/m/R-REC-M.2083-0-201509-!!!PDF-E.pdf.
- [2] IMT-2020 (5G) Promotion Group, “5G Vision and Requirement,” 2015.
- [3] P. Popovski, K. F. Trillingsgaard, O. Simeone, and G. Durisi, “5G wireless network slicing for eMBB, URLLC, and mMTC: A communication-theoretic view,” *IEEE Access*, vol. 6, pp. 55765–55779, 2018, doi: 10.1109/ACCESS.2018.2872781.
- [4] Z. Yousof, “Deliverable D5.1 Definition of connectivity and QoE / QoS management mechanisms – intermediate report,” 2016. [Online]. Available: http://www.it.uc3m.es/wnl/5gnorma/pdf/5g_norma_d5-1.pdf.
- [5] 5gAmericas, “Network Slicing for 5G Networks & Services,” 2016. [Online]. Available: http://www.5gamericas.org/files/3214/7975/0104/5G_Americas_Network_Slicing_11.21_Final.pdf.
- [6] L. Barona López, J. Maestre Vidal, and L. García Villalba, “An Approach to Data Analysis in 5G Networks,” *Entropy*, vol. 19, no. 2, p. 74, 2017, doi: 10.3390/e19020074.
- [7] M. Mullins, Robert; Taynann, “Cognitive Network Management for 5G,” *5GPPP Work. Gr. Netw. Manag. QoS*, vol. 1.02, pp. 1–40, 2017, [Online]. Available: https://5g-ppp.eu/wp-content/uploads/2016/11/NetworkManagement_WhitePaper_1.0.pdf.
- [8] G. A. Akpakwu, B. J. Silva, G. P. Hancke, and A. M. Abu-Mahfouz, “A Survey on 5G Networks for the Internet of Things: Communication Technologies and Challenges,” *IEEE Access*, vol. 6, pp. 3619–3647, 2017, doi: 10.1109/ACCESS.2017.2779844.
- [9] I. Unión Internacional de Telecomunicaciones, *Sentando las bases para la 5G:*

Oportunidades y desafíos. 2018.

- [10] P. V Klaine, M. A. Imran, O. Onireti, and R. D. Souza, "A Survey of Machine Learning Techniques Applied to Self-Organizing Cellular Networks," *IEEE Commun. Surv. Tutorials*, vol. 19, no. 4, pp. 2392–2431, 2017, doi: 10.1109/COMST.2017.2727878.
- [11] V. P. Kafle, Y. Fukushima, P. Martinez-Julia, and T. Miyazawa, "Consideration on automation of 5G network slicing with machine learning," in *10th ITU Academic Conference Kaleidoscope: Machine Learning for a 5G Future, ITU K 2018*, 2018, doi: 10.23919/ITU-WT.2018.8597639.
- [12] L. HUAWEI TECHNOLOGIES CO., "Vo5G Technical White Paper," p. 28, 2018, [Online]. Available: <http://www.huawei.com>.
- [13] Nokia Corporation, "5G use cases and requirements Nokia White Paper 5G Use Cases and Requirements White Paper," 2016. [Online]. Available: www.nokia.com.
- [14] 3GPP ETSI, "TS 22.261 5G; Service requirements for next generation new services and markets (Release 15)," vol. TS 22.261, no. V15.5.0, pp. 0–52, 2018, [Online]. Available: <http://www.etsi.org/standards-search>.
- [15] 3GPP ETSI, "3GPP TS 22.125 Unmanned Aerial System (UAS) support in 3GPP Release 17," 2019.
- [16] The Next Generation Mobile Networks Alliance, "NGMN Perspectives on Vertical Industries and Implications for 5G," Berkshire, UK, 2016. [Online]. Available: https://www.ngmn.org/fileadmin/ngmn/content/images/news/ngmn_news/NGMN_5G_White_Paper_V1_0.pdf.
- [17] Next Generation Mobile Networks Alliance 5G Initiative, "NGMN 5G White Paper," 2015. doi: 10.1021/la100371w.
- [18] P. Schulz *et al.*, "Latency Critical IoT Applications in 5G: Perspective on the Design of Radio Interface and Network Architecture," *IEEE Commun. Mag.*, vol. 55, no. 2, pp. 70–78, 2017, doi: 10.1109/MCOM.2017.1600435CM.

- [19] A. M. Learning, "Evaluación de modelos de ML - Amazon Machine Learning," 2020. https://docs.aws.amazon.com/es_es/machine-learning/latest/dg/evaluating_models.html (accessed Jun. 05, 2020).
- [20] J. E. O. 5G P. Name, Lorca, "Deliverable D2.1 Scenarios , KPIs , use cases and baseline system evaluation," 2017. [Online]. Available: <https://one5g.eu/documents/>.
- [21] W. Chen, Q. Zhao, and H. Duan, "Research on the Key Concepts and Problems of Service Quality," vol. 70, no. Icmeit, pp. 651–654, 2017, doi: 10.2991/icmeit-17.2017.70.
- [22] L. C. Schmelz and C. M. Nok-de, "5G Mobile Network Architecture for diverse services, use cases, and applications in 5G and beyond," 2017. [Online]. Available: https://5g-monarch.eu/wp-content/uploads/2017/10/5G-MoNArch_761445_D6.1_Documentation_of_Requirements_and_KPIs_and_Definition_of_Suitable_Evaluation_Criteria_v1.0.pdf.
- [23] T. Specification and G. Core, "3GPP TS 22.104 Service requirements for cyber-physical control applications in vertical domains," Sophia Antipolis Valbonne, France, 2019.
- [24] TeleManagement Forum and O. Group, *SLA Management Handbook: Enterprise Perspective*, vol. 4, no. October. TMForum, 2004.
- [25] T. Specification and E.-3GPP Group Services, "3GPP TR 23.862," Valbonne, France, 2016. [Online]. Available: <https://itectec.com/archive/3gpp-specification-tr-32-862/>.
- [26] F. Borioni, S (Telemanagement, "SLA Management Handbook," *Tele Manag. Forum*, vol. 4, no. October, 2001, [Online]. Available: <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:SLA+Management+Handbook#3>.
- [27] E. Kapassa, M. Touloupou, and Di. Kyriazis, "SLAs in 5G: A complete framework facilitating VNF- and NS-tailored SLAs management," in *Proceedings - 32nd IEEE International Conference on Advanced Information Networking and Applications*

- Workshops, WAINA 2018*, 2018, vol. 2018-Janua, pp. 469–474, doi: 10.1109/WAINA.2018.00130.
- [28] E. Kapassa, M. Touloupou, A. Mavrogiorgou, and D. Kyriazis, “5G & SLAs: Automated proposition and management of agreements towards QoS enforcement,” *21st Conf. Innov. Clouds, Internet Networks, ICIN 2018*, pp. 1–5, 2018, doi: 10.1109/ICIN.2018.8401587.
- [29] F. Firmin, “The Evolved Packet Core,” *The Mobile Broadband Standard*, 2021. <https://www.3gpp.org/technologies/keywords-acronyms/100-the-evolved-packet-core> (accessed Aug. 07, 2021).
- [30] EventHelix/Medium, “5G Service-Based Architecture (SBA) Towards the 5G core network architecture Evolution from 4G EPC,” 2018. <https://medium.com/5g-nr/5g-service-based-architecture-sba-47900b0ded0a> (accessed Aug. 07, 2021).
- [31] 5G Americas, “5G Services and Use Cases,” 2017. [Online]. Available: http://www.5gamericas.org/files/3215/1190/8811/5G_Services_and_Use_Cases.pdf.
- [32] 3GPP ETSI, “3GPP TS 23.501 System Architecture for the 5G System,” Valbonne, France, 2019. [Online]. Available: <http://www.3gpp.org>.
- [33] H. Zhang, N. Liu, X. Chu, K. Long, A. H. Aghvami, and V. C. M. M. Leung, “Network Slicing Based 5G and Future Mobile Networks: Mobility, Resource Management, and Challenges,” *IEEE Commun. Mag.*, vol. 55, no. August, pp. 138–145, 2017, doi: 10.1109/MCOM.2017.1600940.
- [34] X. Li *et al.*, “Network Slicing for 5G: Challenges and Opportunities,” *IEEE Internet Comput.*, vol. 21, no. 5, pp. 20–27, 2018, doi: 10.1109/MIC.2017.3481355.
- [35] J. W. Zhenyu Zhou, Lu Tan, Bo Gu, Yan Zhang, “Bandwidth Slicing in Sotdware-Defined 5G, A Stackelberg Game Approach,” *ieee Veh. Technol. Mag.* / , no. june, pp. 102–109, 2018.

- [36] M. R. Sama, S. Beker, W. Kiess, and S. Thakolsri, "Service-based slice selection function for 5G," in *2016 IEEE Global Communications Conference (GLOBECOM)*, 2016, doi: 10.1109/GLOCOM.2016.7842265.
- [37] V. K. Choyi, A. Abdel-Hamid, Y. Shah, S. Ferdi, and A. Brusilovsky, "Network slice selection, assignment and routing within 5G Networks," in *2016 IEEE Conference on Standards for Communications and Networking, CSCN 2016*, 2016, no. October, doi: 10.1109/CSCN.2016.7784887.
- [38] Anonymous, "DPI AND 5G : Network visibility and real-time application awareness," Leipzig, Germany, 2019. [Online]. Available: <https://www.thefastmode.com/rohde-and-schwarz-white-papers/15791-white-paper-dpi-and-5g-network-visibility-and-real-time-application-awareness>.
- [39] M. E. Morocho-Cayamcela, H. Lee, and W. Lim, "Machine learning for 5G/B5G mobile and wireless communications: Potential, limitations, and future directions," *IEEE Access*, vol. 7, pp. 137184–137206, 2019, doi: 10.1109/ACCESS.2019.2942390.
- [40] P. Demestichas and A. G. K. Tsagkaris, K, S. Vassaki, "Service classification in 5G networks," no. November. Seoul, South Korea, p. 13, 2016, [Online]. Available: <https://datatracker.ietf.org/meeting/97/materials/slides-97-nmlrg-service-classification-in-5g-networks-00>.
- [41] B. J. Gabriel Cánepa, *What You Need to Know About Machine Learning, Levering data for future telling and data analysis*, no. April. Birmingham, B3 2PB, UK: Packt Publishing Ltd., 2016.
- [42] J. Zamorano Ruiz, "Comparativa y Análisis De Algoritmos de Aprendizaje Automático para la Predicción del Tipo Predominante de Cubierta Arbórea," Universidad Complutense de Madrid, 2018.
- [43] C. Jiang *et al.*, *Machine Learning Paradigms for Next -Generation Wireless Networks*, no. April. 2017.

- [44] C. Wei-Lun, "Machine learning tutorial," *Aec-Apc*. National Taiwan University, Taipei, Tw, p. 56, 2011, [Online]. Available: <http://disp.ee.ntu.edu.tw/~pujols/Machine Learning Tutorial.pdf>.
- [45] E. Borcoci, "Machine Learning Techniques in Advanced Network and Services Management Network and Services Management," in *SoftNet 2019*, 2019, p. 102.
- [46] L. Liyanapathirana, "Classification Model Evaluation," 2018. <https://heartbeat.fritz.ai/classification-model-evaluation-90d743883106> (accessed Jun. 04, 2020).
- [47] Anonymous, "Cross - validation: evaluating estimator performance," *scikit-learn*, 2020. https://scikit-learn.org/stable/modules/cross_validation.html# (accessed Jun. 04, 2020).
- [48] L. B. Raul E., "Machine Learning con Python - Sobreajuste," 2016. <https://relopezbriega.github.io/blog/2016/05/29/machine-learning-con-python-sobreajuste/> (accessed Mar. 20, 2020).
- [49] J. Moysen and L. Giupponi, "From 4G to 5G: Self-organized Network Management meets Machine Learning," pp. 1–23, 2017, [Online]. Available: <http://arxiv.org/abs/1707.09300>.
- [50] L. H. Miguel, "Impacto del Machine Learning en el despliegue de redes 5G," in *10th ITU Academic Conference ITU KALEIDOSCOPE*, 2018, pp. 1–15, [Online]. Available: <https://kaleidoscope.frsf.utn.edu.ar/utn-frsf>.
- [51] S. Asiri, "Machine Learning Classifiers, What is classification?," 2020. <https://towardsdatascience.com/machine-learning-classifiers-a5cc4e1b0623> (accessed Jun. 04, 2020).
- [52] J. I. Bagnato, "Random Forest, el poder del Ensemble, Aprende Machine Learning," 2017. <https://www.aprendemachinelearning.com/random-forest-el-poder-del-ensemble/> (accessed Jun. 04, 2020).

- [53] Z. M. Fadlullah *et al.*, “State-of-the-Art Deep Learning: Evolving Machine Intelligence Toward Tomorrow’s Intelligent Network Traffic Control Systems,” *IEEE Commun. Surv. Tutorials*, vol. 19, no. 4, pp. 2432–2455, 2017, doi: 10.1109/COMST.2017.2707140.
- [54] V. Maini and S. Sabri, *Machine Learning for Humans*, Maini, Sac. 2017.
- [55] S. Van Der Meer, J. Keeney, L. Fallon, J. K. Sven van der Meer, and L. Fallon, “5G networks must be autonomic!,” in *IEEE/IFIP Network Operations and Management Symposium: Cognitive Management in a Cyber World, NOMS 2018*, 2018, doi: 10.1109/NOMS.2018.8406185.
- [56] Unión Internacional de Telecomunicaciones, “ITU-T Y.3170 Requirements for machine learning-based quality of service assurance for the IMT-2020 network,” Switzerland, Geneva, 2018.
- [57] “Quality parameters and standards for Telecommunication networks (Standards and Inspection Guideline),” 2015. [Online]. Available: https://www.sxmregulator.sx/dash/files/Telecommunications/Policies/10t98467537136___UW9TIHN0YW5kYXJkcyBhbmQgaW5zcGVjdGlubiBndWlkZQ==b_64.pdf.
- [58] T. Specification and G. Services, “3GPP TS 22.263 Service requirements for video, imaging and audio for professional applications (VIAPA),” Sophia Antipolis Cedex, France, 2019. [Online]. Available: https://www.3gpp.org/ftp/Specs/archive/22_series/22.263/.
- [59] S. Mumtaz, K. S. Huq, J. Rodriguez, and P. Marques, “D3.2: SPEED-5G enhanced functional and system architecture, scenarios and performance evaluation metrics (v1.0),” 2016.
- [60] U. Keith Briggs, Michael Fitch, Federico Miatton, Herzog, A. Georgakopoulos, I. P. Belikaidis, O. Demestichas, PanagiotisCarrasco, F. Miatton, and K. Moessner, “D4.1: Metric definition and preliminary strategies and algorithms for RM,” 2016.

- [61] T. S. S. O. ITU, "ITU-T T-REC-G.1028-201906-End-to-end quality of service for voice over 4G mobile networks," Geneva, Sw, 2019.
- [62] T. S. S. O. ITU, "ITU-T T-REC-G.1028.2-201906-Assessment of the LTE circuit switched fall back – Impact on voice quality of service," Geneva, Sw, 2019.
- [63] E. 3GPP, "3GPP TS 22.186 - 5G; Service requirements for enhanced V2X scenarios (3GPP TS 22.186 version 15.4.0 Release 15)," Sophia Antipolis Cedex, France, 2018. [Online]. Available: <https://portal.etsi.org/TB/ETSIDeliverableStatus.aspx>.
- [64] P. Varga *et al.*, "5G Support for Industrial IoT Applications – Challenges, Solutions, and Research Gaps," *Sensors (Switzerland)*, vol. 20, no. 3, 2020, doi: 10.3390/s20030828.
- [65] L. Cominardi, L. M. Contreras, C. J. Bcnardos, and I. Berberana, "Understanding QoS Applicability in 5G Transport Networks," *IEEE Int. Symp. Broadband Multimed. Syst. Broadcast. BMSB*, vol. 2018-June, 2018, doi: 10.1109/BMSB.2018.8436847.
- [66] N. M. Sadek, H. H. Halawa, R. M. Daoud, and H. H. Amer, "A Robust Multi-RAT VANET/LTE for Mixed Control & Entertainment Traffic," *J. Transp. Technol.*, vol. 05, no. 02, pp. 113–121, 2015, doi: 10.4236/jtts.2015.52011.
- [67] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, pp. 1–13, 2020, doi: 10.1186/s12864-019-6413-7.
- [68] Baquero-Garcia and J.M, "¿Cómo elegir el lenguaje de programación más adecuado para cada proyecto?," 2015. <https://www.arsys.es/blog/como-elegir-el-lenguaje-de-programacion-adecuado-para-cada-proyecto/> (accessed Jun. 04, 2020).
- [69] L. Toro, "Anaconda Distribution Suite." <https://blog.desdelinux.net/ciencia-de-datos-con-python/> (accessed Jun. 04, 2020).
- [70] D. Jiménez, "Las mejores cinco herramientas de código abierto para la Inteligencia Artificial," 2018. <https://criptotendencia.com/2018/06/23/las-mejores-cinco-herramientas-de-codigo-abierto-para-la-inteligencia-artificial/> (accessed Jun. 04,

2020).

- [71] F. Witten, Ian, Eibe, *Data Mining Practical Machine Learning Tools and techniques, Second Edition*, Second., vol. 53, no. 9. San Francisco, CA.: Elsevier, 2005.
- [72] N. I. Sujan, "What is Entropy and why Information gain matter in Decision Trees?," *Medium*, 2018. <https://medium.com/coinmonks/what-is-entropy-and-why-information-gain-is-matter-4e85d46d2f01> (accessed Jun. 04, 2020).
- [73] J. Wulf, "Analysis and design of value production strategies and business models in the telecommunications industry," Technischen Universität Berlin, 2012.

3 ANEXO 1. Parámetros de KPI y KQI de servicios 5G

La base de datos en formato CSV se elaboró con la ayuda de un grupo de estándares y artículos de los distintos proyectos que se dedican a la estandarización de la red 5G. Los proyectos de donde se extraen los parámetros de KPI y KQI para la formación de la base de datos son: 3GPP, ETSI, Speed, NGMN, 5G América, la ITU y el IMT (referenciados a lo largo de este trabajo). A continuación, se muestran los parámetros de KPI y KQI de los servicios 5G que se tienen en cuenta para este trabajo. Además, se explican consideraciones tomadas para los parámetros asumidos y las referencias de donde fueron tomados.

Tabla 20. Parámetros de KPI para cada servicio 5G (parte uno).

KPI Servicio	Latencia E2E (ms)	Jitter (ms)	Tasa de bit (Mbps)	Relación de pérdida de paquetes (%)	Velocidad de datos pico DL (Gbps)	Velocidad de datos pico UL (Gbps)
Video UHD transmitido en vivo	Mín: 4 [14] [2] Máx: 20 [14] [2]	5.84 [2]	10 [58]	Máx: 1 [2]	20 [2]	10 [2]
Experiencias inmersivas	Mín: 7 [14] Máx: 15 [14]	20 [14]	50 [22]	Máx: 5 [60][59]	20 [2]	10 [2]
Redes inteligentes	Mín: 5 [18] Máx: 50 [18]	1 [18]	1 [58]	Máx: 0.0001 [59]	-	-
e-Salud	Mín: 1 [5] Máx: 10 [5]	-	16 [58]	Máx: 0.00000001 [58]	0.3 [60][59]	0.3 [60][59]
ITS	Mín: 10 [65] [18] Máx: 100 [65] [18]	20 [65]	0.5 [58]	Máx: 0.1 [65] [18]	-	-
Vo5G	Mín: 20 [62] Máx: 150 [20]	30 [20]	10 [58] [62]	Máx: 1 [20]	20 [2]	10 [2]
Vehículos conectados	Mín: 3 [5] [16] Máx: 100 [5] [16]	0.44 [72] [63]	10 [22]	Máx: 0.001 [20] [59]	1 [[16]	0.025 [16]
Automatización de la industria	Mín: 1 [16] Máx: 50 [20] [5]	0.1 [20]	1 [23]	Máx: 0.0000001 [18]	-	-
Vigilancia por video	Mín: 10 [64] Máx: 50 [16] [15]	5 [64]	10 [22]	Máx: 0.001 [5]	0.05 [15]	0.12 [15]

Tabla 21. Parámetros de KPI para cada servicio 5G (parte dos).

KPI Servicio	Movilidad (km/h)	Confiabilidad del servicio (%)
Video UHD transmitido en vivo	Mín: 0 [17] Máx: 500 [17]	Mín: 95 [17]
Experiencias inmersivas	Mín: 0 [20] Máx: 30 [20]	Mín: 95 [2] [1]
Redes inteligentes	Mín: 0 [17] Máx: 0 [17]	Mín: 99.9 [18]
e-Salud	Mín: 0 [5] Máx: 120 [5]	Mín: 99.9999 [20] [59]
ITS	Mín: 50 [18] [65] Máx: 500 [18] [65]	Mín: 99.999 [18] [65]
Vo5G	Mín: 0 [14] Máx: 500 [14]	-
Vehículos conectados	Mín: 50 [16] [63] Máx: 250 [5] [63]	Mín: 99.999 [20] [16]
Automatización de la industria	Mín: 0 [5] Máx: 30 [18]	Mín: 99.999[18] [14]
Vigilancia por video	Mín: 0 [5] Máx: 320 [15]	Mín: 99 [15]

Para los servicios de ITS, redes inteligentes (*smart grid*) y automatización de las industrias (*industry automation*) no se encontraron datos específicos sobre el valor de la tasa de datos pico (*peak data rate*), tanto para DL/UL. Se asumen los valores especificados por la iniciativa de IMT-2020 en [1] para los servicios 5G. Estos valores son de 20Gbps para DL y de 10Gbps para UL.

Asimismo, la bibliografía consultada respecto al servicio de Vo5G, es prácticamente teórica, por lo que no se brindan datos precisos sobre los distintos KPI y KQI que la definen. A razón de esto, se asume un valor de confiabilidad (*reliability*) de un 99.9%, expresada en los estándares de VoLTE que aplican para los servicios de Vo5G según la ITU en [62].

En [73] se plantea que en servicios de e-Salud (*eHealth*) el *jitter*, no debe exceder los 100ms; por este motivo se considerará un *jitter* de 10 ms. Teniendo en cuenta que para en estos servicios tienen lugar aplicaciones de muy baja latencia donde en algunos casos las vidas de los pacientes corren riesgos, y no puede asegurarse que las informaciones críticas de proceso lleguen a tiempo si el *jitter* es demasiado grande o excede los umbrales

Tabla 22. Parámetros de KQI de cada servicio 5G.

KQI Servicio	Disponibilidad (%)	Tiempo de supervivencia (ms)	Tasa de datos de experiencia de usuario DL (Mbps)	Tasa de datos de experiencia de usuario UL (Mbps)	Tiempo de interrupción (ms)
Video UHD transmitido en vivo	Mín: 99 [60] [59] Máx: 99.999 [59] [60]	Mín: 8 [58] Máx: 16 [58]	1000 [14]	500 [14]	Mín: 1000 [1] [58] Máx: 3000 [1] [58]
Experiencias inmersivas	Mín: 99.9 [23]	Mín: 1 [23] Máx: 10 [2]	1000 [14]	50 [20]	0 [20]
Redes inteligentes	Mín: 99.999 [59] [60] [23] Máx: 99.9999 [14] [23]	Mín: 10 [14] [5] Máx: 25 [5] [14]	1 [16]	5 [16]	Casi 0 [2]
e-Salud	Mín: 99 [14] [23] Máx: 99.99999 [59] [60] [23]	Mín: 1 [23] [14] Máx: 50 [14]	0.1 [5] [17]	10 [5] [17] [16]	0 [2] [20]
ITS	99.9999 [14]		10 [5]	10 [5]	1000 [20]
Vo5G	Mín: 95 [14] Máx: 99 [62]	100 [14]	50 [20]	25 [20]	0 [20]
Vehículos conectados	Mín: 95 [14] Máx: 99 [14]	Mín: 1 [23] Máx: 50 [23]	50 [5] [16] [14]	25 [5] [16] [14]	0 [2]
Automatización de la industria	Mín: 99.99 [14] [20] Máx: 99.9999 [14]	Mín: 0 [14] Máx: 100 [14]	100 [20] [14]	1 [14] [20]	Mín: 0 [20] Máx: 100
Vigilancia por video	Mín: 99 [14] [15] Máx: 99.9 [14]	Mín: 10 [23] Máx: 100 [23]	10 [20] [16]	100 [16] [20]	Casi 0 [23]

4 ANEXO 2. Base de datos (*dataset*) creada con valores KPI y KQI de los servicios 5G

Como se indicó en el Anexo 1, la base de datos (*dataset*) se realizó considerando información contenida en bibliografía de un grupo de estándares, reportes de distintos proyectos de instituciones que se dedican a la estandarización de la red 5G, así como de fabricantes y proveedores de servicios de telecomunicaciones. Los proyectos de donde se extraen los parámetros de KPI y KQI para la formación de la base de datos son: 3GPP, ETSI, Speed, NGMN, 5G América, la ITU y el IMT, Nokia, Huawei y otros, los cuales fueron citados en el capítulo 2 y 3. El formato fue CSV tal como se indica en 3.3 Construcción de la base de datos (*dataset*) de los servicios porque los archivos de este tipo son documentos en formato abierto y sencillo para representar datos en forma de tabla. La construcción de la misma se realizó tomando valores aleatorios dentro de los umbrales para cada parámetro. El resultado de la misma se muestra en la Tabla 23 así como en el link <https://zenodo.org/record/4779074#.YK8rd5MzbOQ>, doi:10.5281/zenodo.4779074.

Tabla 23. Dataset de servicios 5G y sus parámetros KPI y KQI

Latency (ms)	Jitter (ms)	Bit Rate (Mbps)	Packet Loss Rate (%)	Peak Data Rate DL (Gbps)	Peak Data Rate UL (Gbps)	Mobility (km/h)	Reliability (%)	Service Availability (%)	Survival Time (ms)	Experienced Data Rate DL (Mbps)	Experienced Data Rate UL (Mbps)	Interruption Time (ms)	Service
15	5	11	0.1	18	7	260	95	99	8	1000	500	1000	UHD_Video_Streaming
5	5.5	10	1	20	10	20	95	99.2	9	990	440	2000	UHD_Video_Streaming
8	10	50	3.8 1.00E-	15	7	15	97	99.9	10	1000	50	0.2	Immerse_Experience
40	1	0.5	05	18	9	0	99.92	99.999	10	5	8	0	Smart_Grid
90	18	0.2	0.08	13	2	480	99.9995	99.9999	100	10	10	1000	ITS
130	5	8	0.9	14	6	400	99.94	95	100	50	25	0	Vo5G
10	19	32	4.7 8.00E-	13	5	26	95.6	99.92	8.9	900	40	0.1	Immerse_Experience
2	3	15	09 0.0007	0.2	0.2	100	99.99996	99	1	10	100	0	e_Health
5	0.5	10	5 1.00E-	0.8	0.024	80	99.9992	99	1	50	25	0	Connected_Vehicles
1	0.05	0.6	07 1.00E-	15	6	28	99.999	99.9999	0	1	10	100	Industry_Automation
8	5	10	08 1.00E-	0.25	0.26	20	99.9999	99.9	50	11	99	1	e_Health
70	4	12	0.001	0.05	0.12	2	99	99	10	10	100	5	Surveillance
7	6	8	0.8	19	5	430	97.8	99.1	8.2	500	300	3000	UHD_Video_Streaming
10	1	0.8	0.0001	15	10	2	99.9	99.9999	11	7	6	0.5	Smart_Grid
32	28	9	1 7.00E-	12	8	50	99.9	95.5	99	49	25	1	Vo5G
40	0.1	0.5	08	12	8	15	99.9991	99.99	50	10	8.4	1	Industry_Automation
15	10	0.5	0.1	18	5	120	99.999	99.99992	10	8	10	2000	ITS
13	5	9	0.0008	0.03	0.14	30	99.87	99.2	50	8	92	10	Surveillance
15	7	10	5	12	10	1	95	99.99	10.1	960	32	0.15	Immerse_Experience
10	0.44	5	0.001	0.7	0.025	200	99.999	95	50	51	20	1	Connected_Vehicles

20	30	10	0.8	19	7	12	99.96	96	98.5	49.5	20	1.5	Vo5G
10	10	12	9.00E-09	0.3	0.3	80	99.99995	99.99	49	12	98	0.2	e_Health
5	1.2	1	8.00E-05	20	5	0	99.93	99.9992	15	10	5	0.3	Smart_Grid
100	0.2	8	0.0002	1	0.03	50	99.9996	98.9	48	49	23	0.5	Connected_Vehicles
50	0.07	1	4.00E-08	8	2	15	99.9994	99.992	99	8	3.2	20	Industry_Automation
1	2	16	7.00E-09	0.4	0.1	5	99.99992	99.9999	2	10	10	0.1	e_Health
10	3	10	0.001	0.06	0.01	300	99.2	99.1	90	9	80	8	Surveillance UHD_Video_Streaming
20	5.84	10	1	20	10	500	96	99.999	15	950	100	2500	ITS
10	20	0.5	0.09	20	10	80	99.9992	99.99991	99	10	9	1500	ITS
150	15	10	0.7	20	5	0	99.95	99	99.2	40	20	0	Vo5G
50	0.8	0.4	9.00E-05	19	8	1	99.9	99.9993	20	5	5	0.1	Smart_Grid
7	20	42	4.2	20	10	30	98	99.992	9.1	980	20	0.3	Immerse_Experience
100	4.2	11	0.0009	0.04	0.11	100	99.1	99.8	15	9.2	95	7	Surveillance
3	0.46	9	0.001	0.9	0.04	160	99.9995	97.5	2	48.9	20	0.2	Connected_Vehicles
100	15	0.43	0.1	15	3	460	99.9995	99.99999	98	7	6	9000	ITS
36	0.08	0.8	1.00E-07	20	10	12	99.999	99.999	100	7	2.5	99	Industry_Automation
5	7	18	9.00E-09	0.27	0.3	70	99.99999	99.999	3	9	15	0.15	e_Health UHD_Video_Streaming
4	5.7	9.8	0.3	19.5	7.8	320	98	99.01	16	1000	100	1100	
8	0.9	0.9	9.80E-05	17.6	7	0	99	99.9998	25	6	10	0.15	Smart_Grid
85	19	0.3	0.09	19	9	500	99.9999	99.99995	100	5	5	10000	ITS
1.2	11	15	1.00E-08	0.32	0.28	90	99.99997	99.99999	48.9	15	85	0	e_Health
12	21	48	5.1	18.8	6.9	10	97.2	99.91	9.6	860	45	0.22	Immerse_Experience
148	31	9.5	1.2	19	9	500	99.92	98.9	99.5	50	18	0.2	Vo5G

25	0.15	1	9.00E-08	10	1	20	99.9995	99.9995	1	6	1	1.5	Industry_Automation
90	0.32	7.6	0.0007	1	0.02	250	99.99987	98	10	49	24	0.15	Connected_Vehicles
151	29	9.2	0.87	17	4	360	99.902	99	50	45	22	0.1	Vo5G
86	4.8	7.33	7.60E-05	0.05	0.13	320	99.04	99.7	100	8.7	99	9	Surveillance
55	0.38	10.1	0.00082	1.2	0.021	76	99.99985	96.5	3	48	21	0	Connected_Vehicles
28	0.75	0.75	6.50E-05	12	6.4	10	99.909	99.9997	24	7	9	0.6	Smart_Grid
66	5.4	9.37	0.00011	0.012	0.09	18	99	99.9	99	3	10	2	Surveillance
9.8	8.4	14.2	1.10E-09	0.3	0.15	120	99.999902	99	49.5	100	78	0.9	e_Health
72	19.5	0.53	0.0908	18	2	50	99.99904	99.99991	95	10	9	1100	ITS
25	28.2	9.8	0.902	19.6	8.3	260	99.98	97	55	49	24	1.5	Vo5G
93	21	0.408	0.102	19.01	3.2	270	99.99903	99.9999	90	10	1	2000	ITS
18	5.62	7.4	0.92	17.3	9.1	26	98.4	99.999	15.4	960	490	1200	UHD_Video_Streaming
48	0.09	0.85	8.00E-08	18	4.1	25	99.99901	99.991	90	8.5	9	10	Industry_Automation
43	0.4	9.04	0.00098	0.09	0.0232	248	99.99909	95.2	2	49	20	1	Connected_Vehicles
7.2	18.9	43.5	4.97	15.2	4.7	24	98.2	99.93	10	870	48	0.01	Immerse_Experience
9.3	9	15.7	8.40E-09	0.22	0.24	55	99.999999	99.99999	50	99	96	0.8	e_Health
78	0.25	11	0.00095	0.91	0.013	170	99.9994	96	48	49.2	21.2	0	Connected_Vehicles
95	4.98	8.6	0.00088	0.05	0.12	280	99.45	99.8	100	2	25	0	Surveillance
1.5	0.092	0.99	8.50E-08	19.5	8.6	30	99.99952	99.9994	98.9	2.2	10	98	Industry_Automation
45	0.84	0.99	7.00E-05	20	9.3	0	99.997	99.999	24.5	8	8	1	Smart_Grid
13	19.4	47	4.35	17.4	6.21	30	95.76	99.96	9.9	970	50	0	Immerse_Experience
16	5.8	9.3	0.86	18	6.5	10	96.2	99.15	10	540	60	2800	UHD_Video_Streaming
140	29.5	3.2	0.743	17.2	5.1	480	99.92	98	80	47	23	0.8	Vo5G

99	18.7	0.41	0.097	16	4	80	99.99954	99.99997	92	7	8	5000	ITS	
8.5	7.5	16	9.50E-08	0.28	0.2	100	99.99994	99.999	10	90	11	0.99	e_Health	
3	0.36	9.25	0.0008	0.81	0.022	230	99.99952	99	49	48.1	24	1	Connected_Vehicles	
16	0.1	0.77	9.90E-08	18.6	7.2	5	99.99948	99.9999	0.2	1.5	5.6	99	Industry_Automation	
12	4.5	9	0.0009	5	0.048	0.1	260	99.025	99	10	7.5	55	15	Surveillance
9	5.4	9.25	0.87	18.3	7.2	450	97.1	99.998	8.1	720	400	3000	UHD_Video_Streaming	
42	0.65	0.95	9.20E-05	15	6.4	3	99.97	99.9999	25	6	6	0	Smart_Grid	
14	17.6	48.8	3.85	19.2	3.4	12	96.5	99.99	9.86	1000	50	0.08	Immerse_Experience	
3	9.2	13.4	9.20E-09	0.25	0.298	60	99.99990	2	99.9999	2	10	15	1	e_Health
75	5.3	8.8	0.0007	2	0.052	0.092	120	99.03	99.1	12	10	100	20	Surveillance
8	0.092	1.2	9.00E-08	12	9.4	21	99.99962	99.9998	10	1	8.7	90	90	Industry_Automation
120	29.8	4.2	0.78	11	2	500	99.97	95.1	90	49	24.8	0.5	Vo5G	
35	0.97	0.54	8.60E-05	3.4	1.2	1	99.91	99.9996	10	5	5	2	Smart_Grid	
17	6.2	8.7	0.72	16.5	5.3	240	95.1	99.995	16	830	360	1000	UHD_Video_Streaming	
98	0.41	9.1	0.0009	5	0.92	0.02	225	99.9996	98.5	50	49.9	25	0.6	Connected_Vehicles
12	16.4	0.35	0.098	12.6	5.1	130	99.99942	99.99998	100	9	9	10000	ITS	
11	5	9.2	0.0009	7	0.041	0.1	310	99	99.5	11	8.6	92	5	Surveillance
3.5	0.44	9.7	0.0009	6	0.99	0.023	50	99.999	97.5	40	50	25	0.4	Connected_Vehicles
1.2	0.099	0.99	9.80E-08	11.6	9	28	99.999	99.997	92	1.2	3.4	85	85	Industry_Automation
1.6	9.6	15.2	9.60E-09	0.3	0.2	110	99.99996	99	1.2	95	12	1.2	1.2	e_Health
7.5	19	50	4.9	15.3	3.1	29	95	99.991	9.75	760	35	0.09	Immerse_Experience	
4.5	5.84	9.1	1	18	9.25	260	95	99.1	15.9	945	430	1900	UHD_Video_Streaming	
82	4.76	9.35	0.001	0.046	0.11	315	99.2	99.9	21	9.1	96	4	4	Surveillance

149	28	8.4	0.9	17	10	10	99.9	95.4	99	49.4	24.9	0.4	Vo5G	
11	19.2	0.5	0.09	20	9.1	50	99.999	99.99991	90	10	5	9800	ITS	
1	9.24	16	8.90E-09	0.25	0.16	55	99.99999	99.9	49.8	100	10	0.2	e_Health	
49	1	0.96	0.0001	12	1	0	99.9	99.9994	10.2	5.2	9	1.2	Smart_Grid	
7.3	20	49.8	5	19.75	9.8	25	97.8	99.9	7.4	500	40	0	Immerse_Experience UHD_Video_Streaming	
4	5.7	10	0.96	17.6	1.2	100	97	99	14.4	450	50	2100		
91	4.84	9.84	0.0009	2	0.048	0.08	200	99.01	99.2	89	9.05	60	3	Surveillance
3.8	0.43	9.9	0.0009	8	0.94	0.019	80	99.9998	99	30	48	20	0.8	Connected_Vehicles
1.6	0.083	0.89	8.90E-08	15.7	7.5	2	99.99902	99.995	85	9.4	2	76	Industry_Automation	
21	26	9.12	1	14.3	2.1	3	99.95	98.9	98.7	46.5	22.6	0.3	Vo5G	
10	18.9	0.46	0.1	18	7.6	499	99.9995	99.9999	80	1	9	9900	ITS	
5	0.98	1	9.90E-05	11	1.5	2	99.902	99.9997	18	7	10	1.1	Smart_Grid	
14.8	19.6	49.9	4.88	20	10	30	96	99.9	9.2	920	40	0.1	Immerse_Experience	
10.5	19	0.4	0.1	12	6	50	99.999	99.99999	99	3	2	1050	ITS	
100	5	10	0.001	0.05	0.112	320	99.1	99.6	98	9.9	70	1	Surveillance	
8	0.1	1	1.00E-07	20	8	30	99.9993	99.999	0	1.9	8	11	Industry_Automation	
100	0.4	10	0.001	1	0.025	250	99.9991	95.1	25	47	23	1	Connected_Vehicles	
148	25	10	1	15	5	60	99.9	99	99.7	47	25	0.25	Vo5G	
19.8	5.82	10	0.976	16	10	160	95.5	99.999	13.3	600	500	2700	UHD_Video_Streaming	
6	0.6	0.85	9.20E-05	15.45	8.6	0	99.915	99.9998	16	8	9	0.1	Smart_Grid	
15	20.2	50	4.75	17.5	3.45	26	97	99.95	10	950	46	0.12	Immerse_Experience UHD_Video_Streaming	
4.2	5	9.81	1.1	12	1	10	95.2	99.9998	10.6	700	200	2900		
9.7	7.5	15	1.00E-08	0.25	0.26	120	99.9999	99.99	49.9	15	92	0.3	e_Health	
15	23	9.46	0.75	16	10	300	99.976	95.9	97	48.2	24.3	0.1	Vo5G	

49	0.098	0.99	1.00E-07	16	5	25	99.9992	99.99	100	10	10	5	Industry_Automation
98	15	0.3	0.097	11	1	480	99.99908	99.99991	89	2	8	1000	ITS
15.1	18.9	49	4.99	12.1	2.11	20	96.8	99.993	9.3	960	20	0.8	Immerse_Experience
10	10	14.3	7.60E-09	0.28	0.29	10	99.999975	99.99999	10	12	100	1.1	e_Health UHD_Video_Streaming
19	4.6	8.7	0.85	15.76	5.2	0	95.36	99.6	12	9000	500	1600	Connected_Vehicles
90	0.35	8.7	0.0009	0.997	0.024	50	99.9992	98.9	1	40	17	0	Immerse_Experience UHD_Video_Streaming
9	16	40	4.1	16.7	7.4	0	95.7	99.93	9.8	1000	50	0.07	ITS
5.5	5.3	9.9	1	17	6	60	96.5	99	12	800	430	2800	Industry_Automation UHD_Video_Streaming
76	15	0.35	0.086	12.4	7.6	55	99.99915	99.9999	100	8	6	8000	ITS
2	0.1	0.8	8.00E-08	18.2	7.1	0	99.999	99.9999	92	5	5	0	Industry_Automation UHD_Video_Streaming
10	5.86	9.98	0.92	18	10	35	97	99.99	13	740	230	1650	Smart_Grid
7	0.4	0.98	0.0001	20	10	0	99.9	99.999	11	7	5	0.6	Vo5G
20	30	9.5	0.996	17.2	6.4	500	99.989	95	100	50	25	0	Immerse_Experience
11	20	25	4.3	20	8	25	95.2	99.9	10	860	40	1	ITS
65	18	0.45	0.09	17	8	50	99.999	99.999	85	9	5	9670	Industry_Automation
10	0.09	0.91	7.20E-08	17.4	6.13	30	99.9991	99.999	87	8	7	1	Smart_Grid UHD_Video_Streaming
12	0.55	0.97	9.00E-05	18.2	7.4	0.2	99.92	99.9999	22	9	6	0.8	Immerse_Experience
16.5	5.5	10	0.7	18.4	7	400	96	99.999	11	960	500	1200	Industry_Automation
12.5	18	30	4.35	17	7	30	95	99.99	12	720	35	1.2	Vo5G
18	0.072	0.97	6.10E-08	16.2	8.4	26	99.9999	99.991	66	6	4	6	Immerse_Experience
30	15	9.8	0.98	20	10	0	99.9	99	110	45	20	2	Industry_Automation
40	16	0.32	0.072	16.1	7	60	99.9991	99.9995	120	8.4	7	1230	Vo5G
15.2	5.4	7.8	0.8	9.4	3	40	95.2	99.98	10	1000	250	3000	ITS UHD_Video_Streaming

15	1	0.82	8.60E-05	17.1	8.9	0.5	99.99	99.9991	20	5	8	1	Smart_Grid
20	0.03	1	1.00E-07	11.8	9.15	27	99.9995	99.992	54	5	9	20	Industry_Automation
14.8	15.5	32	5	18.2	7.1	28	98	99.98	8.6	650	42	0	Immerse_Experience
16	8	0.25	0.1	15.3	8.4	65	99.9999	99.9999	96	9.2	9	3450	ITS
40	16	6.5	1	18.4	7.3	2	99.95	96	98	42	18	3	Vo5G
13.2	5.3	6.4	0.84	16.3	8.4	50	95	99.9	16	780	400	1780	UHD_Video_Streaming
23	0.08	0.75	1.00E-07	13.8	4.1	15	99.9996	99.9998	32	8	2	37	Industry_Automation
36	0.87	1	5.00E-05	16.5	4.1	1	99.91	99.9992	12	7.5	4	2	Smart_Grid
22	7.2	0.23	0.061	12.7	6.1	78	99.9995	99.9996	110	10	10	2000	ITS
10.1	10	41	5.1	13	10	27	97.2	99.91	7.5	870	50	1.5	Immerse_Experience
5	5.8	6.2	0.93	17.7	6.1	10	99	99	8	820	300	2230	UHD_Video_Streaming
100	8	5	0.72	13.7	8.9	3	99.96	98	102	31	10	1.5	Vo5G
31	0.071	0.66	5.00E-08	14.7	8.35	12	99.9999	99.9997	99	7	1	86	Industry_Automation
48	0.91	0.86	9.20E-05	13.3	6.5	0	99.98	99.9995	15	5	10	1.5	Smart_Grid
6.2	5.72	5.7	0.86	15.1	5.66	0	97.3	99.99	9	900	500	1800	UHD_Video_Streaming
18	19.1	0.41	0.05	14.8	7.2	310	99.999	99.9992	105	5	4	8600	ITS
9.8	8.9	44	3.1	12.1	3	22	97.8	99.99	5	920	30	2	Immerse_Experience
135	2	10	0.63	12.6	9.1	430	99.99	97	101	32	11	1.2	Vo5G
55	20	0.5	0.042	19.7	9.8	430	99.9997	99.9991	101	3	1	9500	ITS
30	0.1	0.55	4.00E-08	20	10	2	99.9998	99.998	22	9	9	70	Industry_Automation
7.1	18.2	28	2.8	11.3	2	10	96.3	99.92	8	810	20	1.8	Immerse_Experience
4.5	5.89	9.65	0.97	13.2	6.4	1	95.1	99.997	15	950	280	2950	UHD_Video_Streaming
39	0.95	0.92	9.90E-05	11.8	9.1	2	99.97	99.9999	21	8.2	5	2	Smart_Grid
90	1	8.7	0.99	14.5	8.7	60	99.98	99	105	28	24	0	Vo5G

48	0.093	0.32	4.50E-08	19	1	3	99.9995	99.9999	85	7.1	8.6	3	Industry_Automation
70	11	0.49	0.069	20	10	500	99.9998	99.9998	108	7.5	7	7500	ITS
7	0.094	0.48	8.90E-08	17.1	7.6	1	99.999	99.99	17	8.4	9.1	6	Industry_Automation
8	16.7	29	2.4	19.7	4.5	8	95.9	99.93	11	880	45	1.7	Immerse_Experience
22	0.93	0.88	9.70E-05	10	8.8	0	99.99	99.999	25	9	7	0.1	Smart_Grid

5 ANEXO 3. Tipos de datos de los parámetros de KPI y KQI de los servicios 5G

Al leer la base de datos en el IDE *Jupyter Notebook*, esta se guarda en una variable que tiene como nombre *df*. Para ver el tipo de datos que la librería *Pandas* asigna a los parámetros de KPI y KQI automáticamente se ejecuta la siguiente función: *df.dtypes*. El resultado es la siguiente tabla, donde se muestra el tipo de datos de los parámetros de KPI y KQI correspondiente a los servicios 5G (se le incorpora la columna de descripción para un mejor entendimiento).

Tabla 30: Tipo de datos de los parámetros de KPI y KQI de los servicios 5G.

Parámetros KPI y KQI	Tipo de dato	Descripción
Latencia E2E (ms)	Float64	Son números de poseen parte decimal y parte entera, aunque la parte decimal el valor del punto decimal sea cero. Ocupa un espacio en memoria de 64 bits.
<i>Jitter</i> (ms)	Float64	
Tasa de bits (Mbps)	Float64	
Tasa de pérdida de paquetes (%)	Float64	
Velocidad de datos pico UL (Gbps)	Float64	
Velocidad de datos pico DL (Gbps)	Float64	
Confiabilidad del servicio (%)	Float64	
Disponibilidad del servicio (%)	Float64	
Tiempo de supervivencia (ms)	Float64	
Tasa de datos experimentada por el usuario DL (Mbps)	Float64	
Tasa de datos experimentada por el usuario DL (Mbps)	Float64	
Tiempo de interrupción (ms)	Float64	
Movilidad (km/h)	Int64	Son los valores que no tienen punto decimal, pueden ser positivos o negativos y el cero. Ocupan un espacio de 64 bits en memoria.

6 ANEXO 4. Función para crear el Bosque Aleatorio

Para crear el algoritmo de ML de Bosque Aleatorio a utilizar en la simulación, se empleó la función *RandomForestClassifier* (*input*) de la librería *Scikit Learn*. Donde *input* se refiere al conjunto de variables de entrada que contiene la función. En la siguiente figura se pueden ver estas variables:

```
RandomForestClassifier(bootstrap=True, class_weight=None, criterion='entropy',
                        max_depth=2, max_features='auto', max_leaf_nodes=None,
                        min_impurity_decrease=0.0, min_impurity_split=None,
                        min_samples_leaf=1, min_samples_split=2,
                        min_weight_fraction_leaf=0.0, n_estimators=10,
                        n_jobs=None, oob_score=False, random_state=0, verbose=0,
                        warm_start=False)
```

Figura 31 Variables de entrada de la función *RandomForestClassifier*.

Siendo las variables de entrada más importantes las siguientes: [64]

- *n_estimators*: cantidad de árboles que se quieren generar.
- *max_features*: permite seleccionar la cantidad máxima de características para cada árbol.
- *min_sample_leaf*: número mínimo de elementos en las hojas para permitir una nueva división (*split*) del nodo.
- *oob_score*: método que emula la validación cruzada en árboles y permite mejorar la precisión y evitar sobreajuste.
- *bootstrap*: permite utilizar diversos tamaños de muestras para entrenar el algoritmo. Si se pone en falso, utilizará siempre el conjunto de datos (*dataset*) completo.
- *n_jobs*: si se tienen múltiples núcleos en tu CPU, puedes indicar cuantos puede usar el algoritmo al entrenar para acelerar el entrenamiento.
- *criterion*: los criterios admitidos son “Gini” para la impureza de Gini¹ y “Entropía” para la ganancia de información.

¹ Es una medida de periodicidad de un elemento de ser elegido aleatoriamente del conjunto sería etiquetado incorrectamente, si fue etiquetado de manera aleatoria de acuerdo a la distribución de las etiquetas en el subconjunto.

- *max_depth*: profundidad máxima del árbol. Si es ninguno, los nodos se expanden hasta que todas las hojas sean puras o hasta que todas las hojas contengan menos de *min_samples_split*.