

# Modelo de correlación QoS-QoE en un ambiente de aprovisionamiento de servicios de telecomunicaciones OTT-Telco



**uc3m**

Universidad  
**Carlos III**  
de Madrid

Tesis Doctoral  
Doctorado en Ingeniería Telemática  
Doctorado en Ciencia y Tecnología Informática

**MSc. Julián Andrés Caicedo Muñoz**

Director: Dr. Ing. Álvaro Rendón Gallón (Unicauca)  
Director: Dr. Ing. Agapito Ledezma Espino (UC3M)  
Tutor: Dr. Ing. Juan Carlos Corrales Muñoz (Unicauca)

*Universidad del Cauca*  
*Universidad Carlos III de Madrid*

Popayán, Diciembre de 2021

Esta tesis se distribuye bajo licencia “Creative Commons **Reconocimiento – No Comercial – Sin Obra Derivada**”.



*Esta tesis doctoral está dedicada a:*

*A mis padres Eduardo Caicedo Velásquez y Celma Muñoz Gallego, quienes con su amor, cariño y respeto apoyaron  
cada momento de mi aprendizaje*

*A mi hermana Ana María Caicedo, quien desde la distancia valoró cada esfuerzo realizado.*

*Finalmente, a mis amigos que me alentaron en los momentos difíciles y fortalecieron cada paso de mi formación  
doctoral*

# AGRADECIMIENTOS

Mi profundo agradecimiento a los departamentos de Telemática (Universidad del Cauca - Colombia) e Informática (Universidad Carlos III de Madrid - España), que a través de sus profesores Dr. Álvaro Rendón Gallón y Dr. Agapito Ledezma Espino, respectivamente, orientaron y guiaron el proceso de formación doctoral y el desarrollo del proyecto; sus valiosos aportes y observaciones encaminaron la construcción y finalización de la tesis doctoral, y fortalecieron el aprendizaje dentro del proceso de formación.

Un especial agradecimiento a todos los integrantes del grupo de investigación de Control, Aprendizaje y Optimización de Sistemas (CAOS- UC3M) que me brindaron su apoyo técnico, personal y profesional en cada una de las estancias de investigación realizadas al interior de la Universidad Carlos III de Madrid – España. De igual manera, al personal profesional encargado del centro de datos y de las salas de cómputo del departamento de Informática (UC3M), que potenciaron la experimentación de la tesis.

En el mismo sentido, expreso mis más grande y sincero agradecimiento a la Corporación Universitaria Autónoma del Cauca por su respaldo y apoyo académico dentro del proceso de formación doctoral.

Finalmente, mi agradecimiento al Ministerio de Ciencia, Tecnología e Innovación – Minciencias – por la financiación del proceso de formación doctoral por medio de la convocatoria de doctorados nacionales 727 de 2015.

## CONTENIDO PUBLICADO Y PRESENTADO

Julian A. Caicedo-Muñoz, Agapito Ledezma Espino, Juan Carlos Corrales, Alvaro Redon. "QoS-Classifer for VPN and Non-VPN traffic based on time-related features". Computer Networks, august 2018, ISSN 1389-1286, <https://doi.org/10.1016/j.comnet.2018.08.008>. (SJR/JCR Q1)

- Artículo referenciado y relacionado en los capítulos 4 (sección 4.2.3.1) y 5. El contenido no es presentado como texto en el documento, sino referenciado como un aporte en el desarrollo de la tesis (referencia 186).

Julian A. Caicedo-Muñoz, Agapito Ledezma Espino, Juan Carlos Corrales, Alvaro Redon. "Multi-Agent System for QoE estimation in Over-The-Top services" en LANCOMM'19, May 06-10, 2019, Gramado, Brazil.

- Artículo en evento científico no presentado como texto en el documento

# RESUMEN ESTRUCTURADO

## ANTECEDENTES

El aprovisionamiento de la Calidad de la Experiencia (QoE) en servicios de telecomunicaciones requiere de sistemas de gestión que permitan monitorizar y controlar la QoE de los usuarios luego de consumir diferentes servicios de internet provistos sobre la red del operador. En efecto, el consumo elevado de datos por parte de los usuarios requiere, a nivel de gestión de la red, la asignación de recursos suficientes para el correcto funcionamiento de los servicios. En particular, la configuración de la Calidad del Servicio (QoS) ofrecida por el operador dentro de su dominio de operación se torna fundamental para proveer un tratamiento apropiado del tráfico, permitiendo que la percepción de la calidad del servicio por parte de los usuarios finales pueda mantenerse dentro del umbral de tolerancia de acuerdo con las políticas establecidas por la compañía de telecomunicaciones (Telco). En consecuencia, un modelo de correlación QoS-QoE es clave en el aprovisionamiento de servicios de internet sobre la infraestructura del operador de telecomunicaciones.

## OBJETIVOS

La presente tesis de doctorado se centra en proponer un modelo de correlación QoS-QoE en un ambiente de aprovisionamiento de servicios de telecomunicaciones OTT-Telco. Para ello, cinco acciones generales deben llevarse a cabo; a saber: *(i)* caracterizar los parámetros de QoS que mayor efecto tienen en la degradación de servicios OTT. *(ii)* determinar las características, condiciones, parámetros y medidas de QoE en la prestación de un servicio OTT. *(iii)* establecer las condiciones y restricciones de prestación de un servicio OTT en la infraestructura de una Telco que mantenga una buena relación QoS-QoE. *(iv)* desarrollar un mecanismo de estimación o predicción de QoE con base en los factores de influencia de QoS que afectan la prestación de un servicio OTT. *(v)* evaluar experimentalmente el modelo de correlación QoE-QoS.

## MÉTODOS

Para el cumplimiento de los objetivos, se definió un modelo integrado por un macro-componente Conceptualización y otro Operacional. El macro-componente Conceptualización está orientado por el referente metodológico para la construcción de marcos conceptuales de Jabareen, y el macro-componente Operacional está alineado con las fases definidas para el desarrollo de proyectos de minería de datos, CRISP-DM. Adicionalmente, se emplearon diseños de comprobación para los algoritmos, con el fin de comprobar la validez del modelo de estimación basado en algoritmos de aprendizaje automático; es decir, el modelo de estimación fue evaluado a partir de un diseño de comprobación donde se definen, para cada uno de los algoritmos, los parámetros iniciales de operación, las configuraciones de las diferentes pruebas, y las métricas usadas para evaluar su desempeño.

## RESULTADOS

Los resultados más importantes alcanzados son los siguientes: un mapa estratégico del estado de la ciencia en el aprovisionamiento de la QoE para servicios OTT, una conceptualización de los perfiles del modelo de correlación, un modelo matemático para la valoración de la QoE de acuerdo con el comportamiento de consumo de los usuarios, un conjunto de datos de tráfico etiquetado que relaciona el comportamiento de la red con la percepción de la calidad de los usuarios, y un modelo de estimación de la QoE de los usuarios a partir del comportamiento de tráfico de la red.

## CONCLUSIONES

El modelo de correlación QoS-QoE puede ser empleado en sistemas gestión de la QoE donde se requiere por parte de la Telco un diagnóstico y monitorización más objetiva de la percepción de la calidad del servicio por parte de sus usuarios dentro su red de aprovisionamiento. De igual manera, el empleo de parámetros adicionales de contexto de usuario enriquecería los sistemas de gestión de la QoE en el aprovisionamiento de servicios OTT.

**PALABRAS CLAVE:** Calidad del servicio (QoS), Calidad de la Experiencia (QoE), Servicios OTT, Aprendizaje automático

## STRUCTURED ABSTRACT

### BACKGROUND

Quality of Experience (QoE) provisioning requires robust QoE-centric network and application management on Telco network for providing internet services. Indeed, traffic growth over Telco network demands resource allocation for service well performance. Particularly, Quality of Service (QoS) configuration offered by network provider operational domain becomes a key component for traffic control in a proper manner. Hence, the quality of services perceived can be managed within a tolerance threshold according to telecom operator policies. Therefore, a QoS-QoE correlational model for internet services provisioning over the telecom operator infrastructure is required.

### AIMS

The doctoral thesis is focused on propose a correlation QoS-QoE model for provisioning telecommunications services in OTT-Telco context. To this end, five goals must be accomplishing. *(i)* To characterize QoS parameters that more impact have on OTT services performance. *(ii)* To determinate QoE assumptions, features, parameters, and metrics for OTT service provisioning. *(iii)* To establish the assumptions and restrictions for providing a well QoS-QoE relation in the telecom operator. *(iv)* To develop an estimation model for QoE based on QoS factors in the OTT services provisioning. *(v)* To evaluate the correlation QoS-QoE model.

### METHODS

To accomplish the aims, a model with a Conceptual and Operational macro-component was structured. The Conceptual macro-component is based on the principles for building conceptual frameworks by Jabareen, and an Operational macro-component aligned with data mining project development phases, CRISP-DM. Furthermore, test bed design was structured to validate the estimation model base on machine learning algorithms; namely, algorithms initial parameters, some tests setup, and regression metrics were determined on a test bed for validate the performance of the estimation model proposed

### RESULTS

The most relevant results achieved are the following: a strategic science map in the QoE provisioning for OTT services, three conceptual profiles as part of the correlation QoS-QoE model, a mathematical model for QoE assessment according to user consumption behavior, a label traffic dataset that relates the traffic network with quality of services perception, and estimation QoE model for users based on traffic flows.

### CONCLUSIONS

The QoS-QoE correlational model can be applied in QoE-Driven application and network management in which an objective controlling and monitoring of quality of services perception by users is required. Moreover, additional user context parameters could be taking account for improving the QoE management systems in OTT services provisioning

**KEYWORDS:** Quality of Service (QoS), Quality of Experience (QoE), OTT services, Machine learning models.

## TABLA DE CONTENIDO

Introducción.....	1
CAPÍTULO 1. Contexto general.....	2
1.1. Planteamiento del problema.....	2
1.2. Marco referencial.....	3
1.2.1. Marco conceptual .....	3
1.2.1.1. Calidad del Servicio (QoS, Quality of Service) .....	3
1.2.1.2. Calidad de la Experiencia (QoE, Quality of Experience).....	3
1.2.1.3. Servicios OTT.....	4
1.2.1.4. Relación temática.....	4
1.2.2. Estado del arte .....	5
1.2.2.1. Brechas en áreas temáticas.....	7
1.2.2.2. Brechas en componentes temáticos .....	8
1.3. Objetivos .....	10
1.3.1. Objetivo general.....	10
1.3.2. Objetivos específicos.....	10
1.4. Estructura metodológica.....	10
1.5. Recapitulación.....	10
CAPÍTULO 2. Modelo QoE para servicios OTT.....	12
2.1. Descripción general de la estructura del modelo].....	12
2.2. Descripción del proceso .....	18
2.1. Momento A.....	20
2.2. Momento B.....	21
2.3. Recapitulación.....	23
CAPÍTULO 3. Macro-componente conceptualización .....	24
3.1. Módulo Evolución QoE en OTT.....	24
3.1.1. Definición de las preguntas de búsqueda (SM-1).....	24
3.1.2. Definición de la cadena de búsqueda (SM-2).....	24
3.1.3. Selección de documentos (SM-3).....	25
3.1.4. Identificación de palabras clave (SM-4).....	26
3.1.4.1. Pre-procesamiento:.....	26
3.1.4.2. Extracción de la red:.....	26
3.1.5. Extracción de datos y representación de la documentación (SM-5).....	27
3.1.5.1. Visualización de las categorías conceptuales para el módulo Evolución QoE en OTT .....	27
3.1.5.2. Análisis del módulo Evolución QoE en OTT por periodos de tiempo. ....	39

3.1.6.	Síntesis del módulo Evolución QoE en OTT.....	48
3.2.	Módulo Elementos conceptuales.....	49
3.2.1.	Definición de las preguntas de revisión (SLR-1).....	49
3.2.2.	Identificación de la búsqueda (SLR-2A) .....	49
3.2.3.	Selección de los estudios primarios (SLR-2B).....	50
3.2.3.1.	Criterios de inclusión.....	50
3.2.3.2.	Criterios de exclusión.....	50
3.2.4.	Evaluación de la calidad de los estudios (SLR-2B) .....	51
3.2.5.	Extracción y monitorización de los datos de los estudios seleccionados (SLR-2C).....	53
3.2.6.	Síntesis de los datos (SLR-2D) .....	57
3.2.6.1.	Modelo propuesto.....	57
3.2.6.2.	Servicio o aplicación.....	57
3.2.6.3.	Dominio de aplicación .....	57
3.2.6.4.	Conjunto de datos .....	57
3.2.6.5.	Meta .....	58
3.2.6.6.	Métrica de evaluación de calidad .....	58
3.2.6.7.	Parámetro de medición de calidad.....	58
3.2.6.8.	Identificación y designación de elementos conceptuales del modelo .....	58
3.2.7.	Reporte (SLR-3) .....	59
3.2.8.	Síntesis del módulo Elementos conceptuales .....	60
3.3.	Recapitulación.....	61
CAPÍTULO 4.	Macro-componente operacional .....	62
4.1.	Escenario general .....	62
4.2.	Modelo correlacional QoS-QoE.....	63
4.2.1.	Descripción general .....	63
4.2.2.	Finalidad del modelo correlacional QoS-QoE.....	64
4.2.3.	Construcción del modelo de correlación QoS-QoE .....	65
4.2.3.1.	Módulo de Recolección de datos .....	66
4.2.3.2.	Módulo de Preparación de datos .....	86
4.2.3.3.	Módulo de Modelado.....	112
4.2.4.	Explotación o despliegue del modelo correlacional QoS-QoE .....	133
4.2.4.1.	Módulo Monitorización QoE .....	133
4.2.4.2.	Módulo Control QoE.....	134
4.2.5.	Ejemplo de funcionamiento del modelo correlacional QoS-QoE.....	135
4.3.	Recapitulación.....	139
Capítulo 5.	Conclusiones y recomendaciones.....	141

Referencias .....	145
Anexos .....	156
Anexo A. Aplicación QoE_MOS.....	156
A.1. Descripción general de la aplicación QoE_MOS.....	156
A.2. Procesos de la aplicación QoE_MOS .....	157
2.1. Proceso de detección de servicios de internet.....	157
2.2. Proceso de calificación de la percepción de calidad.....	159
2.3. Proceso de envío de data .....	160
A.3. Implementación de los procesos de la aplicación QoE_MOS.....	161
Anexo B. Protocolo conceptual .....	163
B.1. Antecedentes .....	163
B.2. Preguntas de búsqueda .....	163
Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT .....	163
Parte 2: Análisis de los elementos constituyentes del modelo.....	163
B.3. Proceso de búsqueda .....	164
Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT .....	164
Parte 2: Análisis de los elementos constituyentes del modelo.....	164
B.4. Criterios de selección de estudios.....	165
Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT .....	165
Criterios de inclusión. ....	165
Criterios de exclusión. ....	165
Parte 2: Análisis de los elementos constituyentes del modelo.....	165
Criterios de inclusión. ....	166
Criterios de exclusión. ....	166
B.5. Procedimiento de selección de estudios .....	166
Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT .....	166
Parte 2: Análisis de los elementos constituyentes del modelo.....	166
B.6. Evaluación de calidad .....	167
Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT .....	167
Parte 2: Análisis de los elementos constituyentes del modelo.....	167
B.7. Estrategia de extracción de datos .....	167
Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT .....	167
Parte 2: Análisis de los elementos constituyentes del modelo.....	168
B.8. Síntesis de los datos extraídos.....	168
Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT .....	168
Parte 2: Análisis de los elementos constituyentes del modelo.....	168

## LISTA DE FIGURAS

<b>Figura 1.2.1.</b> Componentes de intersección temática.....	4
<b>Figura 1.2.2.</b> Resultado búsqueda de trabajos por Base de datos [2010-2017].....	6
<b>Figura 2.1.1.</b> Macro-componentes del Modelo QoE para Servicios OTT .....	13
<b>Figura 2.1.2.</b> Fases de un marco de referencia conceptual y CRISP-DM instanciadas por los macro-componentes del modelo QoE para OTT .....	14
<b>Figura 2.1.3.</b> Módulos del modelo QoE para Servicios OTT. ....	14
<b>Figura 2.1.4.</b> Relación de las etapas de los módulos del macro-componente Conceptualización (SM y SLR) y las fases de un marco de referencia conceptual .....	16
<b>Figura 2.1.5.</b> Relación de las etapas del macro-componente Operacional (DM) y las fases de CRISP-DM.....	17
<b>Figura 2.1.6.</b> Relación de las etapas del macro-componente Operacional y las tareas de CRISP-DM. ....	18
<b>Figura 2.2.1.</b> Proceso de ejecución de etapas del modelo QoE para servicios OTT.....	19
<b>Figura 2.2.2.</b> Correspondencias de las salidas del marco de referencia conceptual con las salidas del módulo Evolución QoE en OTT – SM.....	20
<b>Figura 2.2.3.</b> Correspondencias de las salidas del marco de referencia conceptual con las salidas del módulo Elementos conceptuales – SLR .....	21
<b>Figura 2.2.4.</b> Correspondencias de las salidas de CRISP-DM con las salidas del módulo Modelo de correlación de perfiles – DM .....	22
<b>Figura 3.1.1.</b> Mapa de superposición para el módulo Evolución QoE en OTT.....	28
<b>Figura 3.1.2.</b> Mapa longitudinal para el módulo Evolución QoE en OTT – Parte I .....	28
<b>Figura 3.1.2.</b> Mapa longitudinal para el módulo Evolución QoE en OTT – Parte II .....	29
<b>Figura 3.1.2.</b> Mapa longitudinal para el módulo Evolución QoE en OTT – Parte III .....	30
<b>Figura 3.1.3.</b> Diagrama estratégico. ....	31
<b>Figura 3.1.4.</b> Diagrama estratégico por periodos de análisis para el módulo Evolución QoE en OTT. ....	32
<b>Figura 3.1.5.</b> Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte I (2000 a 2005).....	33
<b>Figura 3.1.5.</b> Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte II (2006 a 2010).....	35
<b>Figura 3.1.5.</b> Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte III (2011 a 2015).....	38
<b>Figura 3.1.5.</b> Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte IV (2016 a 2020) .....	39
<b>Figura 4.1.1.</b> Escenario General de aplicación QoE.....	62
<b>Figura 4.2.1.</b> Modelo correlacional QoS-QoE .....	63
<b>Figura 4.2.2.</b> Visión general de la explotación del modelo correlacional QoS-QoE.....	64
<b>Figura 4.2.3.</b> Módulos de construcción del modelo correlacional QoS-QoE.....	65
<b>Figura 4.2.4.</b> Módulo de Recolección de datos.....	67
<b>Figura 4.2.5.</b> Escenario de recolección de datos – Tráfico de red y percepción de la calidad. ....	68
<b>Figura 4.2.6.</b> Componente de red – perfil de servicio (Módulo Recolección de datos).....	68
<b>Figura 4.2.7.</b> Campo DS.....	69
<b>Figura 4.2.8.</b> Estadística descriptiva de los datos de tráfico. ....	74
<b>Figura 4.2.9.</b> Correlación de Spearman de descriptores de tráfico .....	74
<b>Figura 4.2.10.</b> Gráficos univariados de descriptores tráfico.....	76
<b>Figura 4.2.11.</b> Matriz de Correlación (Spearman) de los descriptores de tráfico .....	76
<b>Figura 4.2.12.</b> Componente de usuario – perfil de usuario (Módulo Recolección de datos) .....	77
<b>Figura 4.2.13.</b> Totales registros mes diciembre.....	79

<b>Figura 4.2.14.</b> Totales registros mes enero.....	79
<b>Figura 4.2.15.</b> Totales registros mes febrero.....	80
<b>Figura 4.2.16.</b> Totales registros mes marzo.....	80
<b>Figura 4.2.17.</b> Totales registros mes abril.....	80
<b>Figura 4.2.18.</b> Totales registros mes mayo.....	80
<b>Figura 4.2.19.</b> Totales registros mes junio.....	80
<b>Figura 4.2.20.</b> Total de registros.....	80
<b>Figura 4.2.21.</b> Estadística descriptiva de los datos de la percepción de la calidad para sesiones etiquetadas.....	82
<b>Figura 4.2.22.</b> Correlación de Pearson de descriptores de la percepción de la calidad para sesiones etiquetadas.....	83
<b>Figura 4.2.23.</b> Gráficos univariados de descriptores de la percepción de la calidad para sesiones etiquetadas.....	84
<b>Figura 4.2.24.</b> Gráficos multivariados de descriptores de la percepción de la calidad para sesiones etiquetadas.....	84
<b>Figura 4.2.25.</b> Tareas generales en la fase de preparación de datos.....	86
<b>Figura 4.2.26.</b> Visión general de técnicas de limpieza de datos.....	87
<b>Figura 4.2.27.</b> Visión general de técnicas de selección de características.....	87
<b>Figura 4.2.28.</b> Visión general de técnicas transformación datos.....	88
<b>Figura 4.2.29.</b> Visión general de técnicas de reducción de dimensionalidad.....	88
<b>Figura 4.2.30.</b> Marco general de tareas de preparación de datos en contexto.....	89
<b>Figura 4.2.31.</b> Esquema de técnicas para la selección de características.....	91
<b>Figura 4.2.32.</b> Tareas de transformación de datos.....	92
<b>Figura 4.2.33.</b> Relevancia de descriptores numéricos de tráfico sobre la variable objetivo $qt$ .....	99
<b>Figura 4.2.34.</b> Reporte de la tarea de limpieza para el conjunto de datos de tráfico – perfil paramétrico.....	101
<b>Figura 4.2.35.</b> Módulo de Preparación de datos del modelo de correlación.....	102
<b>Figura 4.2.36.</b> Componente de usuario – perfil de usuario (Módulo Preparación de datos).....	103
<b>Figura 4.2.37.</b> Implementación bloque Raw data – perfil de usuario (Módulo Preparación de datos).....	103
<b>Figura 4.2.38.</b> Implementación del bloque Preparación – perfil de usuario (Módulo Preparación de datos).....	104
<b>Figura 4.2.39.</b> Procesos del modelo matemático para el cálculo QoSpt.....	105
<b>Figura 4.2.40.</b> Componente de red – perfil paramétrico (Módulo de Preparación de datos).....	108
<b>Figura 4.2.41.</b> Implementación del bloque Raw data – perfil paramétrico (Módulo Preparación de datos).....	109
<b>Figura 4.2.42.</b> Proceso de fusión de datos de tráfico y evaluación general de la percepción de la calidad.....	110
<b>Figura 4.2.43.</b> Implementación del bloque Preparación – perfil paramétrico (Módulo Preparación de datos).....	111
<b>Figura 4.2.44.</b> Módulo de Modelado del modelo de correlación.....	113
<b>Figura 4.2.45.</b> Componente semi_supervisado – perfil de usuario (Módulo Modelado).....	114
<b>Figura 4.2.46.</b> Arquitecturas de máquinas de Boltzmann y codificador automático.....	116
<b>Figura 4.2.47.</b> Arquitectura SAE Greedy layer-wise.....	117
<b>Figura 4.2.48.</b> Arquitectura CNN con SAE Greedy layer-wise.....	117
<b>Figura 4.2.49.</b> Arquitectura DNN implementada.....	117
<b>Figura 4.2.50.</b> Arquitectura MLP implementada.....	118
<b>Figura 4.2.51.</b> Número de niveles óptimos para SAE-Greedy y CNN/SAE-Greedy.....	119
<b>Figura 4.2.52.</b> Resultados MAE/MSE con algoritmos de redes neuronales – descriptor $qt$ no transformado.....	123
<b>Figura 4.2.53.</b> Resultados MAE/MSE con algoritmos de redes neuronales – descriptor $qt$ transformado.....	124
<b>Figura 4.2.54.</b> Resultados MAE/MSE con algoritmos estandarizados – descriptor $qt$ no transformado.....	126
<b>Figura 4.2.55.</b> Resultados MAE/MSE con algoritmos estandarizados – descriptor $qt$ transformado.....	127
<b>Figura 4.2.56.</b> Esquema semisupervisado para el perfil de usuario.....	128
<b>Figura 4.2.57.</b> Componente estimación – perfil paramétrico (Módulo Modelado).....	129
<b>Figura 4.2.58.</b> Resultados MAE/MSE con algoritmos MLP – descriptor $qt$ transformado.....	131
<b>Figura 4.2.59.</b> Resultados MAE/MSE con algoritmos estandarizados – descriptor $qt$ transformado.....	132
<b>Figura 4.2.60.</b> Diagrama de explotación del modelo correlacional QoS-QoE – Sistema de Gestión QoE.....	133
<b>Figura 4.2.61.</b> Mapa de conversión de la escala absoluta MOS en categoría subjetiva MOS.....	134
<b>Figura 4.2.62.</b> Reporte de resultados de preparación (Monitorización – preparación).....	136
<b>Figura 4.2.63.</b> NQoE_P para un lote de datos de tráfico (Monitorización - Predicción).....	136

<b>Figura 4.2.64.</b> NQoE_E para un lote de datos de tráfico (Control - Marcación) .....	138
<b>Figura 4.2.65.</b> Reporte de control QoE (Control - comparación de niveles/reporte).....	138
<b>Figura A.1.1.</b> Procesos de la aplicación QoE_MOS .....	156
<b>Figura A.2.1.</b> Funciones de los procesos de la aplicación QoE_MOS. ....	157
<b>Figura A.2.2.</b> Flujo de ejecución de las funciones del proceso de detección de servicios de Internet. ....	157
<b>Figura A.2.3.</b> Flujo de ejecución de las funciones del proceso de calificación de la percepción de calidad.....	159
<b>Figura A.2.4.</b> Flujo de ejecución de las funciones del proceso de envío de data. ....	160
<b>Figura A.3.1.</b> Implementación de los procesos QoE_MOS. ....	161
<b>Figura A.3.2.</b> Solicitud de permiso de evaluación.....	161
<b>Figura A.3.3.</b> Interfaz de calificación según métrica MOS. ....	161
<b>Figura A.3.4.</b> Formato de servicios calificados. ....	162

## LISTA DE TABLAS

<b>Tabla 3.1.1.</b> Productos de la etapa SM-1 y del módulo Evolución QoE en OTT.....	24
<b>Tabla 3.1.2.</b> Cantidad estudios por librería digital .....	25
<b>Tabla 3.1.3.</b> Cantidad estudios por librería digital con cadena de búsqueda delimitada. ....	25
<b>Tabla 3.1.4.</b> Productos de la etapa SM-2 y del módulo Evolución QoE en OTT.....	25
<b>Tabla 3.1.5.</b> Productos de la etapa SM-3 y del módulo Evolución QoE en OTT.....	26
<b>Tabla 3.1.6.</b> Grupos conceptuales del módulo Evolución QoE en OTT .....	27
<b>Tabla 3.1.7.</b> Productos de la etapa SM-4 y del módulo Evolución QoE en OTT.....	27
<b>Tabla 3.1.8.</b> Categorías conceptuales más representativas para el periodo de análisis 2000 a 2004.....	40
<b>Tabla 3.1.9.</b> Autores más representativos para el periodo de análisis 2000 a 2004.....	41
<b>Tabla 3.1.10.</b> Categorías conceptuales más representativas para el periodo de análisis 2005 a 2010.....	42
<b>Tabla 3.1.11.</b> Autores más representativos para el periodo de análisis 2005 a 2010.....	42
<b>Tabla 3.1.12.</b> Categorías conceptuales más representativas para el periodo de análisis 2011 a 2015.....	44
<b>Tabla 3.1.13.</b> Autores más representativos para el periodo de análisis 2011 a 2015.....	45
<b>Tabla 3.1.14.</b> Categorías conceptuales más representativas para el periodo de análisis 2016 a 2020.....	46
<b>Tabla 3.1.15.</b> Autores más representativos para el periodo de análisis 2016 a 2020.....	47
<b>Tabla 3.1.16.</b> Productos de la etapa SM-5 y del módulo Evolución QoE en OTT.....	47
<b>Tabla 3.2.1.</b> Productos de la etapa SLR-1 y del módulo Elementos conceptuales.....	49
<b>Tabla 3.2.2.</b> Cantidad de especificaciones técnicas por organismos de estandarización y control. ....	50
<b>Tabla 3.2.3.</b> Productos de la etapa SLR-2A y del módulo Elementos conceptuales. ....	50
<b>Tabla 3.2.4.</b> Productos de la etapa SLR-2B y del módulo Elementos conceptuales. ....	50
<b>Tabla 3.2.5.</b> Estudios clasificados por categoría y relación conceptual para el periodo 2016-2020 - Resumen.....	51
<b>Tabla 3.2.6.</b> Rangos de relevancia por categoría y relación conceptual.....	52
<b>Tabla 3.2.7.</b> Etiquetado de estudios con base en el IAA.....	53
<b>Tabla 3.2.8.</b> Productos de la etapa SLR-2B y del módulo Elementos conceptuales. ....	53
<b>Tabla 3.2.9.</b> Matriz de características esenciales del modelo QoE para servicios OTT – Parte I.....	55
<b>Tabla 3.2.10.</b> Matriz de características esenciales del modelo QoE para servicios OTT – Parte II.....	56
<b>Tabla 3.2.11.</b> Productos de la etapa SLR-2C y del módulo Elementos conceptuales. ....	56
<b>Tabla 3.2.12.</b> Productos de la etapa SLR-2D y del módulo Elementos conceptuales. ....	59
<b>Tabla 3.2.13.</b> Revistas científicas más representativas en el contexto del aprovisionamiento de QoE para servicios OTT. ....	59
<b>Tabla 3.2.14.</b> Productos de la etapa SLR-3 y del módulo Elementos conceptuales.....	59
<b>Tabla 4.2.1.</b> Descripción general de datos de tráfico de red por monitorización de flujos. ....	70
<b>Tabla 4.2.2.</b> Descriptores válidos de los flujos recolectados.....	71
<b>Tabla 4.2.3.</b> Subconjunto de datos y datos totales de tráfico.....	71
<b>Tabla 4.2.4.</b> Resumen datos estadísticos de descriptores de tráfico.....	72

<b>Tabla 4.2.5.</b> Cantidad de datos flujos individuales y bidireccionales de tráfico de red – Dimensión de los datos. ....	73
<b>Tabla 4.2.6.</b> Tipo de datos de los descriptores de tráfico.....	74
<b>Tabla 4.2.7.</b> Sesgo de distribución de los descriptores de tráfico. ....	75
<b>Tabla 4.2.8.</b> Media y mediana de los descriptores de tráfico. ....	75
<b>Tabla 4.2.9.</b> Descripción general de datos de percepción de calidad. ....	79
<b>Tabla 4.2.10.</b> Elementos de la percepción de la calidad del servicio. ....	81
<b>Tabla 4.2.11.</b> Descriptores de la percepción de la calidad del servicio.....	81
<b>Tabla 4.2.12.</b> Cantidad de datos etiquetados y no etiquetados de la percepción de la calidad – Dimensión de los datos .....	82
<b>Tabla 4.2.13.</b> Tipo de datos de los descriptores de percepción de la calidad.....	82
<b>Tabla 4.2.14.</b> Sesgo de distribución de los descriptores de la percepción de la calidad para sesiones etiquetadas...	83
<b>Tabla 4.2.15.</b> Media y mediana de los descriptores de la percepción de la calidad para sesiones etiquetadas.....	83
<b>Tabla 4.2.16.</b> Valores lambda para diferentes transformada de potencia.....	94
<b>Tabla 4.2.17.</b> Grado de aplicación de las tareas del marco general de preparación de datos .....	96
<b>Tabla 4.2.18.</b> Correspondencia de las tareas de preparación de datos.....	97
<b>Tabla 4.2.19.</b> Dimensión de los datos de tráfico para los perfiles de servicio y paramétrico .....	98
<b>Tabla 4.2.20.</b> Relevancia de los descriptores numéricos de tráfico sobre la variable qt.....	99
<b>Tabla 4.2.21.</b> Implementación de tareas CRISP-DM en el Componente semi_supervisado del perfil de usuario.....	114
<b>Tabla 4.2.22.</b> Algoritmos de uso recurrente en problemas de regresión.....	114
<b>Tabla 4.2.23.</b> Diseño de comprobación.....	115
<b>Tabla 4.2.24.</b> Dimensión de los datos dentro de la fase de preparación. ....	116
<b>Tabla 4.2.25.</b> Estructura SAE Greedy.....	119
<b>Tabla 4.2.26.</b> Estructura CNN con SAE-Greedy .....	119
<b>Tabla 4.2.27.</b> Estructura DNN fija implementada.....	120
<b>Tabla 4.2.28.</b> Estructura CNN fija implementada.....	120
<b>Tabla 4.2.29.</b> Estructura MLP implementada.....	120
<b>Tabla 4.2.30.</b> Configuración de evaluación del algoritmo SAE-Greedy .....	121
<b>Tabla 4.2.31.</b> Configuración de evaluación del algoritmo SNN/SAE-Greedy.....	121
<b>Tabla 4.2.32.</b> Configuración de evaluación del algoritmo DNN/CNN.....	121
<b>Tabla 4.2.33.</b> Configuración de evaluación del algoritmo MLP.....	121
<b>Tabla 4.2.34.</b> Configuración de evaluación de los algoritmos de uso estandarizado.....	122
<b>Tabla 4.2.35.</b> Comparación de distribución de datos base y predichos por algoritmo – Prueba Kolmogorov-Smirnov .....	127
<b>Tabla 4.2.36.</b> Implementación de tareas CRISP-DM en el Componente estimación del perfil paramétrico .....	129
<b>Tabla 4.2.37.</b> Diseño de comprobación.....	130
<b>Tabla 4.2.38.</b> Configuración de evaluación del algoritmo MLP.....	131
<b>Tabla 4.2.39.</b> Configuración de evaluación de los algoritmos de uso estandarizado.....	131
<b>Tabla 4.2.40.</b> Conversión DSCP a categoría MOS por políticas de QoS.....	137
<b>Tabla 4.2.41.</b> Conversión valor decimal <i>tos</i> a categoría MOS.....	137
<b>Tabla A.1.1</b> Formato de las salidas de los procesos de QoE_MOS.....	156
<b>Tabla A.2.1.</b> Resumen de funciones del proceso de detección de servicios de Internet.....	158
<b>Tabla A.2.2.</b> Resumen de funciones del proceso de calificación de la percepción de calidad. ....	160
<b>Tabla A.2.2.</b> Resumen de funciones del proceso de envío de data.....	161
<b>Tabla B.2.1.</b> Relación de etapas del modelo QoE para OTT con las preguntas de búsqueda.....	164
<b>Tabla B.3.1.</b> Relación de etapas del modelo QoE para OTT con el proceso de búsqueda.....	165
<b>Tabla B.4.1.</b> Relación de etapas del modelo QoE para OTT con los criterios de selección de los estudios .....	166
<b>Tabla B.5.1.</b> Relación de etapas del modelo QoE para OTT con el procedimiento de selección de los estudios .....	167
<b>Tabla B.6.1.</b> Relación de etapas del modelo QoE para OTT con la evaluación de la calidad de los estudios .....	167
<b>Tabla B.7.1.</b> Relación de etapas del modelo QoE para OTT con la estrategia para extracción de los datos.....	168
<b>Tabla B.8.1.</b> Relación de etapas del modelo QoE para OTT con la síntesis de los datos.....	168

**Tabla B.9.1.** Relación de etapas del modelo QoE para OTT con la presentación de los resultados ..... 169

# INTRODUCCIÓN

El modelo correlacional QoS-QoE pretende definir un mecanismo que relacione la Calidad del Servicio (QoS, *Quality of Service*) en la prestación de un servicio de comunicaciones, con la Calidad de Experiencia (QoE, *Quality of Experience*) de un usuario toda vez que este haya consumido el servicio. Para ello, el modelo basado en datos utilizará técnicas de aprendizaje automático con el ánimo de estimar-predecir, a partir de la QoS entregada al usuario, un valor o nivel adecuado en la QoE para un conjunto de usuarios clasificados, inicialmente, por su comportamiento de consumo; en consecuencia, una Telco podrá contar con un insumo para tomar decisiones a nivel técnico, tecnológico y de negocio que propendan por el mejoramiento de la QoS de los servicios entregados al usuario final a partir de la calidad experimentada por estos.

En resumen, el modelo correlacional QoE-QoS estima la QoE en el aprovisionamiento de servicios OTT bajo condiciones o criterios de QoS en el dominio del operador de telecomunicaciones. Para ello, un modelo QoE para servicios OTT ha sido propuesto a partir de la ejecución de un conjunto de etapas bien definidas.

El trabajo de investigación está estructurado de la siguiente manera:

- *Capítulo 1:* describe el marco de referencia del estudio, destacándose la base conceptual y el estado del arte del área de conocimiento y de sus núcleos temáticos. Adicionalmente, se presenta el problema de investigación, los objetivos, y la estructura metodológica general.
- *Capítulo 2:* describe la estructura general del modelo QoE para servicios OTT, las etapas del proceso de definición, conceptualización, operación e implementación del modelo; por último, se relacionan las salidas de cada etapa con sus respectivos productos.
- *Capítulo 3:* detalla el análisis, desarrollo e implementación del macro-componente Conceptualización del modelo QoE para servicios OTT.
- *Capítulo 4:* detalla el análisis, desarrollo e implementación del macro-componente Operacional del modelo QoE para servicios OTT.
- *Capítulo 5:* presenta las conclusiones y recomendaciones del trabajo a partir de los resultados obtenidos en cada uno de los macro-componentes del modelo de correlación QoS-QoE.

Finalmente, en los anexos se encuentra información complementaria sobre los temas tratados; organizados de la siguiente manera:

- *Anexo A:* describe el funcionamiento de la aplicación QoE\_MOS para la captura de datos de percepción de la calidad por parte de un usuario final.
- *Anexo B:* describe el protocolo conceptual para la construcción del macro-componente Conceptualización del modelo QoE para servicios OTT.

# CAPÍTULO 1. CONTEXTO GENERAL

## 1.1. PLANTEAMIENTO DEL PROBLEMA

El continuo crecimiento de los servicios en Internet es un hecho notorio; un dramático consumo de datos se está presentado en la red del proveedor [1] [2]. En el año 2020, el tráfico IP mensual alcanzó 25 GB per cápita, incrementando por 15 GB lo alcanzado en 2015 [3]. Un alto porcentaje de este tráfico fue debido al consumo de video móvil, especialmente contenido provisto por operadores *Over-The-Top* (OTT) [4].

Los servicios ofrecidos por los operadores OTT han impactado drásticamente a la baja los ingresos percibidos por las Telco [4], afectando el modelo de negocio que habían consolidado por varias décadas. Algunas de las consideraciones que han inclinado a los consumidores de servicios de telecomunicaciones y de entretenimiento por servicios OTT comprenden factores como el costo del servicio, disponibilidad de contenido multimedia, penetración de internet móvil y de celulares inteligentes, experiencia de usuario y neutralidad de la red [4]. Este último, implica que toda Telco oferte, sin restricción, cualquier servicio presente en la red; no obstante, las Telco han perdido la capacidad de aumentar su portafolio de servicios frente aquellos que han logrado aumentar de manera significativa su oferta (i.e servicios OTT). Para afrontar lo anterior, las Telco han optado por establecer alianzas estratégicas con los OTT para la prestación de nuevos servicios de telecomunicaciones y entretenimiento [5], implicando una transformación en su modelo de negocio.

La relación OTT-Telco está siendo abordada desde varios puntos de vista, particularmente, desde una perspectiva centrada en el usuario final (i.e. *user-centric approaches*), donde existe un interés por parte de la academia y de la industria por ofrecer una buena Calidad de la Experiencia (QoE, *Quality of Experience*) en la prestación de los servicios [6]. Sin embargo, mantener una adecuada QoE requiere, desde una perspectiva técnica y tecnológica, mantener, diferenciar y mejorar la calidad del servicio (QoS, *Quality of Service*) sin realizar cambios drásticos en la infraestructura del operador que impliquen elevados costos de implementación. En ese sentido, la definición de la correlación QoS-QoE sobresale como un mecanismo propicio para la reestructuración de plataformas de aprovisionamiento de servicios, entendiendo que los usuarios finales cumplen un rol clave y esencial en el modelo de negocio (e.g. nuevas estrategias de retención de clientes, optimización y gestión eficiente de redes, adaptación de las plataformas de aprovisionamiento de servicios – integración de plataformas de despliegue de servicios).

Teniendo en cuenta ese panorama, el proyecto de doctorado se enfocó en la relación existente entre un operador OTT, una Telco y un usuario final, definiendo un modelo de correlación entre QoS y QoE para un conjunto de servicios específicos de telecomunicaciones; entendiéndose como una relación mutua, no necesariamente lineal ni de causalidad, donde cierto grado de dependencia afecta el comportamiento de una o de otra. Para ello, algunas preguntas de investigación fueron inicialmente declaradas a partir de la pregunta de investigación base: *¿Cómo modelar la relación QoS-QoE en un ambiente de aprovisionamiento de servicios de telecomunicaciones OTT-Telco?*

- ¿Cuáles son los elementos o parámetros de QoS que tienen mayor impacto en la degradación de la calidad de un conjunto de servicios específicos de telecomunicaciones?
- ¿Cómo afecta la degradación de la QoS en la percepción que tiene el usuario final al momento de consumir un servicio OTT a través de la infraestructura de red de la Telco?
- ¿Cuáles son las restricciones y condiciones técnicas de implantación de un servicio OTT que mantengan una adecuada relación QoS-QoE?
- ¿Qué ambiente de validación permite comprobar la precisión y efectividad del modelo de correlación QoE-QoS?

Finalmente, se presenta la siguiente hipótesis de trabajo: un modelo paramétrico QoS-QoE con base en técnicas o algoritmos de Aprendizaje Automático, permitirá adaptar con mayor efectividad la prestación de servicios OTT al interior de la infraestructura de un operador de telecomunicaciones (IAP, *Internet Access Provider*), logrando mantener o mejorar los sistemas de QoE sin que se realicen cambios tecnológicos drásticos que desencadenen altos costos de implementación.

## 1.2. MARCO REFERENCIAL

Para establecer el marco investigativo del proyecto, se ha establecido un marco conceptual y estado del arte como elementos científico-tecnológicos que orientan el objeto de estudio de la tesis doctoral. En ese sentido, el marco conceptual describe los componentes temáticos que cubre la investigación; el estado del arte presenta los trabajos relacionados, el estado actual de conocimiento, las tendencias o enfoques futuros, las brechas que existen y el vacío que llenaría el desarrollo del proyecto.

### 1.2.1. Marco conceptual

En esta sección se presentan las principales áreas o módulos temáticos que involucran el desarrollo del proyecto de doctorado, producto de un análisis inicial y general de la relación QoS-QoE en un ambiente de aprovisionamiento de servicios OTT-Telco.

#### 1.2.1.1. Calidad del Servicio (QoS, Quality of Service)

La QoS ha sido un concepto asociado a las comunicaciones que ha sufrido un cambio de dirección en la última década, pasando de una orientación estrictamente técnica en el contexto de red del operador (i.e. desempeño de la red), a una orientación más general basada en la percepción del usuario [7]. En efecto, el sector de normalización de la Unión Internacional de Telecomunicaciones (ITU-T) ha actualizado el concepto en su recomendación E.800 como “*La totalidad de las características de un servicio de telecomunicaciones que determinan su capacidad para satisfacer las necesidades implícitas y explícitas del usuario del servicio*” [8]. En ella se destaca el módulo de QoS percibida por el cliente (QoSE o QoSP, *QoS Experienced by Customer*), el cual expresa el nivel de calidad que el usuario o el cliente cree haber experimentado. Si bien la recomendación incluye una aproximación más orientada al usuario, aún existe un vacío metodológico y técnico en cómo traducir el desempeño de la red, medido en parámetros de red y de servicio, a elementos percibidos o experimentados por el usuario, medidos en parámetros de satisfacción.

#### 1.2.1.2. Calidad de la Experiencia (QoE, Quality of Experience)

La QoE ha venido ganando en pocos años mucha atención por parte de la industria y la academia, principalmente, por ser un tópico que afecta considerablemente la retención de clientes para un proveedor de servicios de telecomunicaciones. En ese sentido, el seminario Dagstuhl ha venido trabajando en varios aspectos conceptuales de QoE, en particular, el seminario 12181 [9] ha concluido que la QoE debe entenderse como “*el grado de deleite o disgusto de un usuario de una aplicación o servicio, el cual resulta del cumplimiento de sus expectativas con respecto a la utilidad o disfrute del servicio o aplicación a la luz del estado actual o personalidad del usuario*” [10].

El panorama presentado requiere de un análisis con mayor profundidad de aquellos aspectos que impactan la QoE; en especial, la identificación de los factores de influencia (IF, *Influence Factor*) son uno de los puntos clave de investigación [11]. En ese sentido, Ulrich Reiter et al. [12] agrupan los IF en tres categorías: Humanos (HIF, *Human IF*), Contexto (CIF, *Context IF*) y de Sistema (SIFs, *System IF*). Los primeros, definidos como cualquier propiedad o característica variante o invariante de un ser humano; los segundos, corresponden con factores que abarcan cualquier propiedad situacional para describir el ambiente del usuario; los terceros, hacen referencia a las propiedades y características que determinan la calidad producida técnicamente de una aplicación o servicio.

En particular, los SIF presentan una sub-clasificación que relaciona elementos de desempeño de red con la calidad percibida de un usuario en una aplicación o un servicio específico. En consecuencia, el estudio de la relación entre parámetros técnicos de red y de percepción del usuario se torna importante en la medida que se caractericen los elementos que influyen de manera directa e indirecta la QoS con la QoE.

### 1.2.1.3. Servicios OTT

Los servicios OTT, entendidos como servicios que ofrecen audio, video, texto y contenido multimedia sobre Internet [4], han venido afectando el modelo de negocio de los operadores de telecomunicaciones; en efecto, los operadores móviles han experimentado un decremento en sus ingresos y aumento en costos operativos dentro del aprovisionamiento del servicio [5]. Adicionalmente, el incremento exponencial de suscriptores de servicios OTT (e.g. Netflix con 167 millones de suscriptores de pago al final del año 2019 [13]) ha generado un aumento dramático del tráfico inyectado sobre las redes del operador de telecomunicaciones, causando problemas de congestión complejos de controlar y solventar, siendo las aplicaciones de video las que registran los comportamientos más acelerados [4].

En consecuencia, una caracterización y parametrización de los servicios con mayor proyección deberá desarrollarse con el objeto de lograr una adaptación rápida en la infraestructura de red de la Telco y una prestación del servicio transparente al usuario final y con un uso eficiente de los recursos de red.

### 1.2.1.4. Relación temática

Teniendo en cuenta las áreas temáticas presentadas, la Figura 1.2.1 expone la relación entre cada una de ellas con el fin localizar puntos de interés dentro del proyecto de doctorado. Cada una de las intersecciones temáticas resuelve aspectos investigativos más específicos, delimitando el alcance del proyecto.

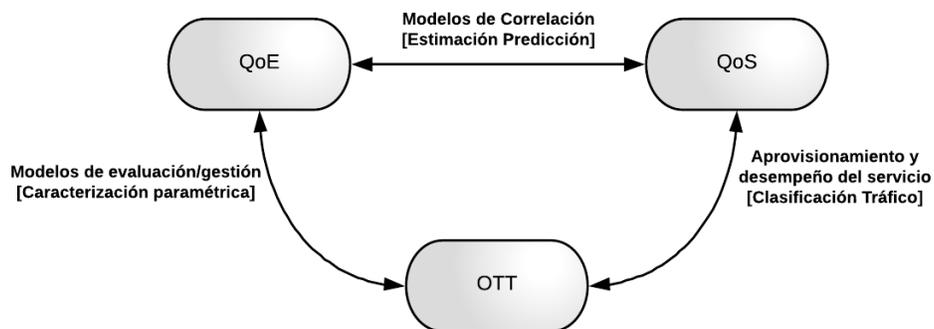


Figura 1.2.1. Componentes de intersección temática

#### A. Relación temática servicio OTT y QoE

El punto de intersección entre las áreas temáticas QoE y OTT recae en la elaboración de elementos de parametrización y caracterización de los servicios OTT con base en sus propiedades funcionales y técnicas para el aprovisionamiento de QoE. En consecuencia, modelos de gestión basados en QoE (*QoE-based models*) sobresalen como foco de interés por parte de un operador OTT-Telco.

#### B. Relación temática servicio OTT y QoS

El punto de intersección entre las áreas temáticas QoS y OTT se centra en el estudio de desempeño de un servicio OTT en términos de su funcionamiento, rendimiento y control. Los modelos basados en QoS tienen como punto de partida el análisis de altos volúmenes de tráfico y del deterioro que experimentan los servicios por una red con altos índices de congestión. Diferentes técnicas de Aprendizaje Automático (ML, *Machine*

*Learning*) han sido utilizadas para determinar el comportamiento de un servicio OTT en una red de telecomunicaciones, especialmente, en una red IP (e.g. Máquinas de Vector de Soporte - SVM, Árboles de Decisión - DT, Redes Neuronales Recurrentes - RNN).

### **C. Relación temática QoE y QoS**

El punto de intersección entre las áreas temáticas QoE y QoS presenta la construcción de modelos de estimación y/o predicción de componentes de satisfacción del usuario en relación con el consumo de un servicio. En efecto, la relación técnica entre las condiciones red, a través de la parametrización de la QoS, y de la ponderación de QoE, es el principal enfoque de análisis en la detección de elementos de correlación QoE-QoS. En este contexto, las técnicas de ML fortalecen el desarrollo de modelos predictivos relacionados con el impacto que la degradación de la QoS tiene sobre la QoE de un servicio OTT.

#### **1.2.2. Estado del arte**

La revisión general de trabajos relacionados fue realizada según la metodología de Kai Petersen et al. [14] para cada una de las áreas y componentes de intersección temática. La revisión se realizó en las bases de datos científicas ScienceDirect, SpringerLink, IEEEXplore, Scopus, ACM DL, para el periodo comprendido entre los años 2010-2017. La Figura 1.2.2 presenta el resultado obtenido.

Es importante resaltar que el objeto del estado del arte difiere de la finalidad de la primera iteración del modelo QoE para servicios OTT que será explicada en el Capítulo 2 (Figura 2.1.4); mientras que el referente teórico es el mismo, los objetivos son diferentes. Para el estado del arte, se busca una visión general de las áreas temáticas QoE, QoS, y OTT, mientras que en la iteración uno del modelo se buscan las condiciones específicas en el aprovisionamiento de la QoE para servicios OTT bajo criterios de QoS del operador de telecomunicaciones. No obstante, el estado del arte puede ser considerado como una fase cero que permita encaminar la definición del modelo.

SearchString	Scientific Database (2010-2017)						Etiqueta
	Scopus	IEEE	ScienceDirect	SpringerLink	ACM	Total	
<b>Áreas o Módulos Temáticos</b>							
<b>Módulo Calidad de la Experiencia (QoE)</b>							
("QoE" OR "Quality of Experience")	9.611	1.982	1.359	2.943	513	16408	QoE
("QoE-Based" OR "QoE-Driven" OR "QoE-Aware")	1665	349	93	220	38	2365	QoE-based
("Models" OR "Methodology" OR "Framework") AND ("QoE-Aware" OR "QoE-Based")	927	76	75	191	17	1286	QoE-Model
("Estimation" OR "Prediction") AND ("QoE" OR "Quality of Experience")							
<b>Módulo Calidad del Servicio (QoS)</b>							
("QoS" OR "Quality of Service")	89124	14339	22445	28574	1212	155694	QoS
("QoS-Based" OR "QoS-Aware")	14902	28	1041	2193	84	18248	QoS-Aware
("Models" OR "Methodology" OR "Framework") AND ("QoS-Aware" OR "QoS-Based")	11181	31	1026	2145	46	14429	QoS-Model
<b>Módulo Servicios Over-The-Top (OTT)</b>							
("OTT services" OR "Over The Top Services" OR "IP Services")	711	88	309	454	10	1572	OTT
("OTT services" OR "Over The Top Services") AND ("Provisioning" OR "Delivery")	55	43	68	84	2	252	OTT-Provision
<b>Componentes de Intersección Temáticos</b>							
<b>Componente Temático QoE-OTT</b>							
("QoE-Based" OR "QoE-Driven" OR "QoE-Aware") AND ("Over The Top Services" OR "OTT" OR "IP Services")	71	11	7	18	1	108	QoE-Based/OTT
<b>Componente temático QoE-QoS</b>							
("QoE") AND ("QoS") AND ("Correlation" OR "Relationship") AND ("Models" OR "Methodology" OR "Framework")	662	153	265	718	6	1804	QoE-QoS Correlation
<b>Componente temático OTT-QoS</b>							
("QoS-Based" OR "QoS-Aware") AND ("Over The Top Services" OR "OTT")	96	47	9	12	0	164	QoS-OTT
<b>Componente Temático QoE-QoS-OTT</b>							
("QoE") AND ("QoS") AND ("Correlation" OR "Relationship") AND ("Models" OR "Methodology" OR "Framework") AND ("Over The Top Services" OR "OTT")	19	6	7	29	1	62	QoE-QoS-OTT relationship

Figura 1.2.2. Resultado búsqueda de trabajos por Base de datos [2010-2017]

Como puede verse en la Figura 1.2.2, existe un gran interés por parte de la comunidad científica en entender el contexto de QoE (total de artículos: 16.408, con etiqueta QoE); sin embargo, los modelos de gestión orientados por QoE aún están en una fase temprana de investigación, especialmente, aquellos modelos de prestación de servicios en un dominio OTT-Telco (total de artículos: 96, con etiqueta QoE-Based/OTT).

Por otro lado, los modelos de QoS para el estudio del comportamiento de servicios OTT se centran en la caracterización de tráfico y el efecto sobre el desempeño de la red. En consecuencia, aproximaciones relacionadas con categorización, clasificación y discriminación de tráfico surgen como enfoques novedosos en la estimación y predicción de QoE en un ambiente de aprovisionamiento OTT-Telco (total de artículos: 164 y 62, con etiquetas QoS-OTT y QoE-QoS-OTT, respectivamente).

Finalmente, una creciente tendencia se presenta en estudios que relacionan el desempeño de la red con la calidad percibida por el usuario al momento de consumir un servicio de telecomunicaciones, especialmente, aquellos provistos sobre la red IP (total de artículos: 1.622, con etiqueta QoS-QoE correlation).

### 1.2.2.1. Brechas en áreas temáticas

Teniendo en cuenta la revisión de trabajos relacionados para cada área y componente de intersección temática (Figura 1.2.2), se detectaron algunas inconsistencias o brechas que podían ser tratadas, desarrolladas o reducidas en el desarrollo del proyecto de doctorado.

#### A. Área temática QoS

El estudio de QoS es un campo ampliamente discutido y en continuo desarrollo, principalmente por los desafíos que surgen al desplegar nuevos servicios de comunicaciones. Trabajos como [15] se han centrado en revisar las arquitecturas de aprovisionamiento de QoS y otros como [16] en proponer mecanismos alternos de tratamiento de QoS basado en la diferenciación de servicios.

Investigaciones recientes como las expuestas en [17] [18] [19] [20] se enfocan en suministrar mecanismos basados en QoS optimizados para contextos tecnológicos y de aprovisionamiento de servicios y de red que crecen en popularidad (e.g. entornos ubicuos, internet de las cosas, redes de sensores inalámbricos, redes definidas por software). En ese sentido, nuevos modelos de QoS o adaptaciones de los enfoques ya existentes deben ser desarrollados con el objeto de mantener un correcto aprovisionamiento del servicio, sin afectar negativamente la percepción de calidad ni el desempeño del mismo.

#### B. Área temática QoE

La QoE presenta un gran desafío para la comunidad científica; varios puntos clave de investigación han sido definidos con el propósito de tener un panorama más claro del concepto y una aplicación concreta de modelos de gestión, de medición y de evaluación objetiva en nuevos dominios de aprovisionamiento de servicios [11]. Trabajos como [21] y [22] presentan aproximaciones metodológicas para el modelado de la QoE basado en factores con mayor influencia en la percepción de la calidad del usuario en un servicio o aplicación.

Por otro lado, estudios como [23] y [24] describen mecanismos para la evaluación, monitorización y medición de la QoE en contextos donde las aplicaciones sean provistas de manera transparente, con uso eficiente y flexible de recursos, y cumpliendo con los requerimientos, necesidades y expectativas del cliente. De igual manera, trabajos como [25] [26] y [27] miden el impacto generado por el bajo desempeño de un determinado servicio sobre la red en la QoE del usuario.

Finalmente, se resalta la importancia de contar con mecanismos de estimación y predicción de QoE para la toma acertada y oportuna de decisiones en el aprovisionamiento del servicio; aproximaciones como [28] [29] y [30] describen modelos de cuantificación de la QoE con el objeto de diseñar técnicas de gestión de red y de experiencia del cliente.

#### C. Área temática OTT

Los estudios realizados alrededor del aprovisionamiento de este tipo de servicios podrían clasificarse en tres aspectos: Regulación, Negocio y Técnicos. El primero, enfocado en asuntos regulatorios en relación con su implementación, prestación y operación; trabajos como [31] [32] y [33] describen el panorama de la prestación de estos servicios y de las estrategias que podrían implementarse para regular el mercado de los mismos. El segundo, centrado en la adaptaciones y reestructuración de los modelos de negocio de los operadores, llevando a cabo la integración de los servicios OTT con la infraestructura de aprovisionamiento, de operación y de negocio; estudios como [34] [35] [36] [37] y [38] exponen estrategias para una integración entre la infraestructura

de una Telco y el despliegue de servicios OTT con el objeto de adaptarse a un mercado con altas exigencias en QoS. Finalmente, aspectos técnicos como los considerados en [39] [6] y [40] sugieren mecanismos que habiliten ciertas condiciones satisfactorias en el aprovisionamiento de los servicios, cumpliendo con las necesidades y expectativas de los usuarios, y sin afectar negativamente la percepción de calidad.

### 1.2.2.2. Brechas en componentes temáticos

#### A. Componente de intersección temática QoE-QoS

La relación entre los elementos de red (QoS) y elementos de QoE, es medida en términos de la degradación que puede ser experimentada por un servicio y el impacto que tiene esta sobre la percepción de calidad que tiene el usuario. Mohammed et al. [41], describen las técnicas y los enfoques más representativos orientados a encontrar la relación entre QoS-QoE (e.g. IQX hipótesis, VQM-based, Análisis estadístico, Crowdsourcing para test subjetivos). En efecto, los enfoques propuestos describen mecanismos unidireccionales, donde los parámetros de aplicación y de red se comportan como factores condicionantes en la QoE. Una de las técnicas más empleada y prometedora está basada en modelos construidos a partir del análisis de la información o de un conjunto de datos de un servicio en particular, destacándose la implementación de una variedad de algoritmos de ML [41].

Algunas técnicas de ML han sido evaluadas en varios estudios, en particular, técnicas de aprendizaje supervisado basadas en métodos de regresión por mínimos cuadrados y por redes neuronales [42], y métodos de clasificación como Máquinas de Vector de Soporte (SVM), Árboles de Decisión (DT), Naive Bayes (NB), Vecino más Cercano (k-NN) y Random Forest (RF) [42]. Trabajos como [43] [44] [45] y [46] presentan estudios donde se visualiza el efecto que tiene la degradación de la QoS en la QoE del usuario para el consumo de un servicio de telecomunicaciones (e.g. servicios OTT).

De igual manera se destacan los siguientes puntos:

- Sólo se considera un tipo de parámetro de QoS (*jitter*, ancho de banda, retardo, pérdida de paquetes).
- Cuando se tienen en cuenta varios parámetros de QoS, sólo se considera el efecto individual de cada parámetro para una métrica específica de QoE (MOS/OS/PVQ).
- Sólo se contempla un tipo específico de servicio (*Video Streaming* o VoIP).
- La métrica MOS (*Mean Opinion Score*) es la clase objetivo que predomina en cada uno de los modelos propuestos.
- Deben tenerse en cuenta aproximaciones no supervisadas, principalmente porque algunos conjuntos de datos de una Telco presentan datos no etiquetados, registrando sólo eventos de comunicaciones como llamadas, conexiones de internet y envío de mensajes [47].
- Deben considerarse técnicas de ML en un contexto online como aquellos modelos definidos por Vlado Menkovski et al. en [48], principalmente, por tener la red un comportamiento dinámico en la prestación de un servicio en el dominio OTT-Telco.

Lo anterior implica que la tesis doctoral estudie la manera en que los parámetros de QoS afectan en conjunto a una o varias métricas de QoE, y cómo pueden variar de peso de acuerdo al contexto donde se preste el servicio OTT (e.g. función de agregación de pesos y caracterización de parámetros). Adicionalmente, la correlación entre QoE-QoS debe presentarse como un mecanismo donde se pueda estimar o predecir cualesquiera de los parámetros o criterios de calidad a partir del conocimiento obtenido de ellos (tanto QoS como QoE).

#### B. Componente de intersección temática QoE-OTT

La cantidad de factores que influyen la QoE implica el análisis de modelos complejos y con un alto nivel de subjetividad. En consecuencia, deben estudiarse aquellos que pueden ser evaluados en un ambiente

controlado, específicamente, aquellos factores relacionados con el sistema que afectan la percepción de la calidad. Los factores de sistema (SIF, *System Influence Factors*) entendidos como propiedades o características que determinan la calidad técnica producida por una aplicación o servicio [12], contemplan una subcategoría de elementos de Red (*Network-related*) que relaciona la degradación de la QoS con el deterioro de la QoE. Sin embargo, aún no es clara la conexión de dichos elementos de desempeño de red con la calidad percibida por el usuario al momento de consumir un servicio en ambiente de aprovisionamiento OTT-Telco. De igual manera, existen varios desafíos en la prestación de los servicios donde se mantenga la QoE al momento de consumir un tipo de servicio; Huang Feng-hui en [39] destaca las condiciones de evaluación, cuantificación y factores de influencia que pueden afectar la percepción de calidad en redes con mayores capacidades de transporte y de recursos como las 5G

Adicionalmente, se pueden resaltar los siguientes vacíos:

- Para servicios OTT las condiciones y restricciones de red que afectan la QoE están siendo exploradas; retos como mantener las características de QoE de un servicio OTT a través de la disponibilidad de recursos de red de una Telco se presenta como foco reciente de investigación [39] [49].
- Existe la necesidad de adaptar técnicas de minería de datos o de aprendizaje automático para comprender el impacto de los SIF en la QoE.
- El escenario Telco-OTT es un campo poco explorado, especialmente en proveer una óptima QoS que mantenga una buena QoE en el consumo de un servicio OTT.
- Hay un aumento de trabajos que enfocan sus esfuerzos en encontrar la relación QoE-OTT o en gestionar recursos de red con base en modelos de gestión orientados en QoE (*QoE-Based*), especialmente; revisiones realizadas por Raimund Schatz et al. en [50], presentan como aproximación prometedora para el aprovisionamiento de servicios de comunicaciones en un entorno OTT-Telco, la combinación de modelos de gestión de Red y de Aplicación, donde coexiste la relación de elementos de red y elementos de calidad percibida por el usuario. Sin embargo, esta aproximación requiere de un esfuerzo conjunto y una coordinación efectiva donde el usuario sea el centro del modelo de integración y no el desempeño de la red.

Las anteriores consideraciones enfocan el estudio en modelos de gestión centrados en el usuario final y orientado en QoE para el aprovisionamiento efectivo de un servicio OTT; en consecuencia, el modelo de correlación debe contemplar la caracterización de un servicio en términos de aprovisionamiento en un entorno OTT con el objeto de mantener y asegurar la calidad del servicio requerida por el usuario final. En ese sentido, la evaluación de la calidad percibida por el usuario del servicio se considera clave para la toma de decisiones de un operador OTT en relación con la prestación del servicio.

### **C. Componente de intersección temática OTT-QoS**

El análisis de comportamiento de los servicios OTT sobre la red IP se centra en el estudio de tráfico y de deterioro en la prestación debida a la degradación de la red. La clasificación y caracterización de tráfico sirve para definir políticas de seguridad, de facturación, y en especial, para establecer condiciones de QoS sobre la red [51]. Para esta última, los operadores de telecomunicaciones consideran relevante una clasificación adecuada de tráfico en la cual se tomen decisiones de aprovisionamiento del servicio con base en los recursos que más se demanden (e.g ancho de banda, velocidad). Trabajos como [52] [53] y [54] presentan modelos de clasificación como mecanismo de mejora progresiva del desempeño de la red.

De igual manera, se resaltan los siguientes puntos:

- No se cuenta con trabajos suficientes de caracterización de tráfico para tratamiento de QoE en servicios OTT.

- La mayoría de los trabajos se enfocan en la clasificación de tipo de tráfico base (voz, video, chat, *web browsing*), pero no determinan la procedencia del mismo (servicio o aplicación)
- Los principales enfoques consideran la inspección profunda de paquetes (DPI, *Deep Packet Inspection*), lo cual toma elevados tiempos de procesamiento y genera flujos de información que podrían afectar el desempeño de la red [55].
- Aproximaciones basadas en medición de flujo de paquetes a través de un análisis estadístico y de comportamiento, sobresalen por su enfoque no invasivo en la red [56]. Para ello, las técnicas de ML se tornan una solución potente en la construcción de modelos de clasificación de tráfico [51] [57] [6] (e.g. SVM, DT, RNN).

Teniendo en cuenta lo anterior, el modelo de correlación debería considerar modelos de clasificación y caracterización de tráfico para la asignación dinámica de recursos de red que mejoren el desempeño y la QoS de los servicios OTT.

## 1.3. OBJETIVOS

### 1.3.1. Objetivo general

Proponer un modelo de correlación QoS-QoE en un ambiente de aprovisionamiento de telecomunicaciones OTT-Telco.

### 1.3.2. Objetivos específicos

- 1) Caracterizar los parámetros de QoS que mayor efecto tienen en la degradación de servicios OTT.
- 2) Determinar las características, condiciones, parámetros y medidas de QoE en la prestación de un servicio OTT.
- 3) Establecer las condiciones y restricciones de prestación de un servicio OTT en la infraestructura de una Telco que mantenga una buena relación QoS-QoE.
- 4) Desarrollar un mecanismo de estimación o predicción de QoE con base en los factores de influencia de QoS que afectan la prestación de un servicio OTT.
- 5) Evaluar experimentalmente el modelo de correlación QoE-QoS.

## 1.4. ESTRUCTURA METODOLÓGICA

El enfoque metodológico para el desarrollo de la tesis doctoral parte de las especificaciones dispuestas por el “Modelo Integral para el Profesional en Ingeniería” [58], y materializado por los referentes metodológicos de K. Petersen et al. en [14], B. Kitchenham en [59], y CRISP-DM [60]. Por su parte, el modelo QoE para servicios OTT sigue una configuración específica en su proceso de definición, conceptualización, operación e implementación de cada uno de los referentes teóricos con el ánimo de estimar un nivel de QoE para servicios OTT de usuarios finales bajo condiciones de QoS del operador de telecomunicaciones (ver Capítulo 2).

## 1.5. RECAPITULACIÓN

En este capítulo se describió el contexto general de la tesis doctoral, resaltando los aspectos fundamentales para la comprensión del fenómeno de estudio; a saber: un planteamiento del problema, donde se plantea la necesidad de las Telco de estimar un valor de la QoE a partir de la QoS entregada a sus usuarios al momento de consumir servicios OTT; un marco referencial, que describe la base conceptual de la tesis y presenta los hallazgos generales en relación con el estado actual del conocimiento de cada área temática relacionada; unos objetivos, que definen el propósito y alcance del proyecto de doctorado; y una estructura metodológica, que relaciona los principales referentes para el desarrollo de la tesis.

En síntesis, este capítulo permite conocer el panorama general del área de estudio, de sus elementos y características, su alcance y la forma de estructurar su desarrollo.

## CAPÍTULO 2. MODELO QOE PARA SERVICIOS OTT

En el presente capítulo se describe la estructura del modelo QoE para servicios OTT en términos de sus macro-componentes, módulos, y etapas del proceso de definición, conceptualización, operación e implementación.

### 2.1. DESCRIPCIÓN GENERAL DE LA ESTRUCTURA DEL MODELO

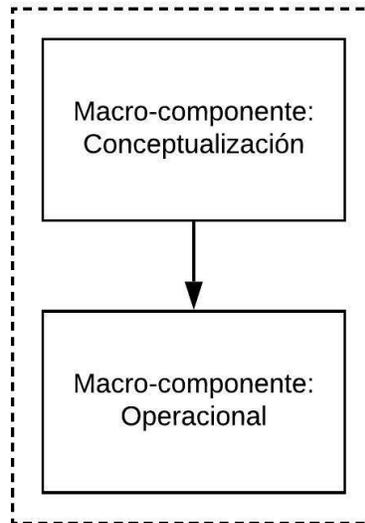
El modelo QoE para servicios OTT tiene como finalidad estimar un nivel de QoE a partir de las condiciones de QoS entregadas por una Telco al momento de consumir servicios OTT por parte de sus usuarios. Para ello, se definen dos macro-componentes (ver Figura 2.1.1). El primero, denominado Conceptualización, analiza a profundidad la evolución de la ciencia alrededor del aprovisionamiento de QoE para servicios OTT bajo condiciones de QoS, y define los elementos conceptuales del modelo; el segundo, denominado Operacional, especifica un modelo basado en datos para la estimación de la QoE a partir sus elementos conceptuales y del entendimiento del contexto de la QoE para servicios OTT.

El macro-componente Conceptualización sigue los lineamientos metodológicos propuestos por Y. Jabareen et al. [61], Kai Petersen et al. en [14], B. Kitchenham et al. en [59]; mientras el macro-componente Operacional está orientado por las tareas definidas en cada fase de la metodología CRISP-DM [60].

La metodología de Y. Jabareen et al. [61] define un proceso para la construcción de marcos de referencia conceptuales que permitan un entendimiento completo del fenómeno de estudio, el establecimiento de los conceptos, y la identificación de los elementos, variables, y relaciones necesarias de cada concepto para resolver un problema de manera generalizada. Dada la continua y rápida evolución de los servicios de telecomunicaciones como también de la propia conceptualización y tratamiento de QoS y QoE, se ha considerado esencial incluir en el modelo de correlación una sección basada en esta metodología, para dotarlo de la capacidad de entregar resultados acordes con las necesidades de los operadores y fundamentados en los avances más recientes sobre el tema. Ahora bien, en este referente metodológico no se detallan las acciones para la implementación de cada una de las fases definidas; en consecuencia, las metodologías de Petersen y Kitchenham fueron adaptadas dentro de las tres primeras fases del marco de referencia conceptual de Jabareen, teniendo en cuenta que estas son las necesarias para la comprensión completa del fenómeno de estudio y el establecimiento de los conceptos que lo representan (ver Figura 2.1.2).

Los referentes metodológicos de Petersen y Kitchenham permiten, en conjunto, conocer el estado de la evolución de la ciencia en el área de la QoE, y los elementos conceptuales en el aprovisionamiento de la QoE a partir de condiciones específicas de QoS en el consumo de servicios OTT. Estos elementos conceptuales son representados por los perfiles del modelo QoE para servicios OTT (i.e perfil de servicio, perfil de usuario y perfil paramétrico)

Por otro lado, CRISP-DM [60] presenta las fases y sus actividades que guían el proceso de un proyecto de minería de datos. En particular, este referente fue empleado en la creación de un modelo basado en datos para la estimación de un valor de la QoE a partir de unas condiciones de tráfico presentes en la infraestructura de red de una Telco. Su fase inicial, denominada comprensión del negocio, es el punto de partida donde se requiere de un entendimiento claro y preciso del entorno objeto de estudio, y del establecimiento de una meta específica que pueda ser alcanzada a partir de los datos recolectados en cada uno de los elementos más representativos del contexto. En ese sentido, la salida del macro-componente Conceptualización establece la base sobre la cual se desarrolla un modelo de estimación de la QoE a partir de los datos recolectados en cada uno de los elementos conceptuales o perfiles identificados (ver Figura 2.1.1).



**Figura 2.1.1.** Macro-componentes del Modelo QoE para Servicios OTT

Para cada macro-componente de la Figura 2.1.1 se implementó un conjunto de fases y actividades de acuerdo con el referente metodológico sobre el cual estos se desarrollan y bajo unas condiciones específicas (ver figuras 2.1.2, 2.1.4, 2.1.5, y 2.1.6); a saber:

- El macro-componente Conceptualización implementa las fases 1, 2, y 3 definidas por Y. Jabareen [61]: mapeo de las fuentes de datos de documentos de la temática, extensiva lectura y categorización de los documentos seleccionados, e identificación y designación de conceptos (ver Figura 2.1.2).
- El macro-componente Operacional implementa las fases 1 a 4, y 6 de CRISP-DM [60]: comprensión del negocio, comprensión de los datos, preparación de los datos, modelado, y distribución (ver Figura 2.1.2).

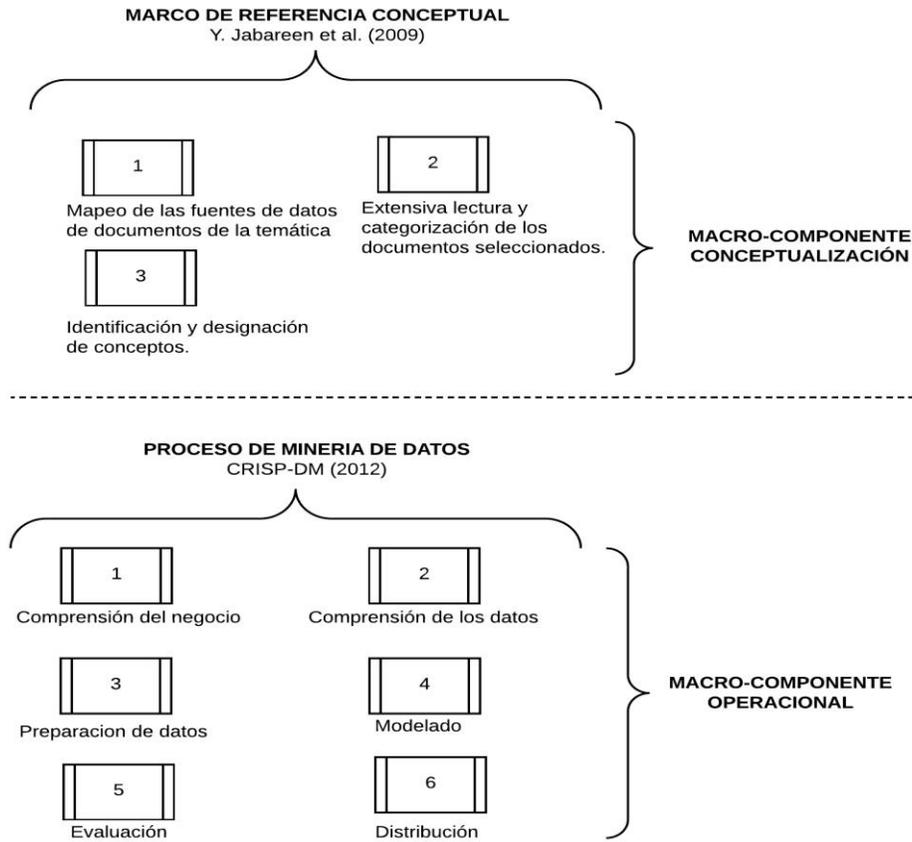


Figura 2.1.2. Fases de un marco de referencia conceptual y CRISP-DM instanciadas por los macro-componentes del modelo QoE para OTT

El modelo QoE para servicios OTT tiene un conjunto de módulos que hacen parte de cada macro-componente y que fueron desarrollados a partir de los referentes metodológicos anteriormente mencionados; a saber (ver Figura 2.1.3):

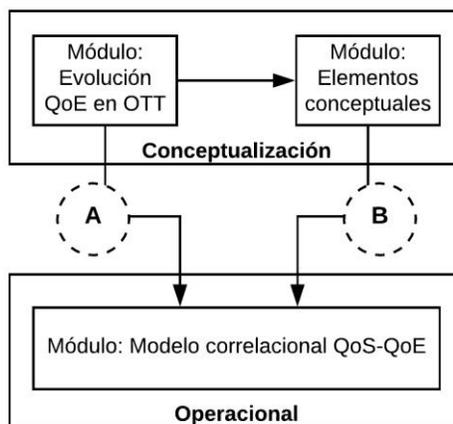
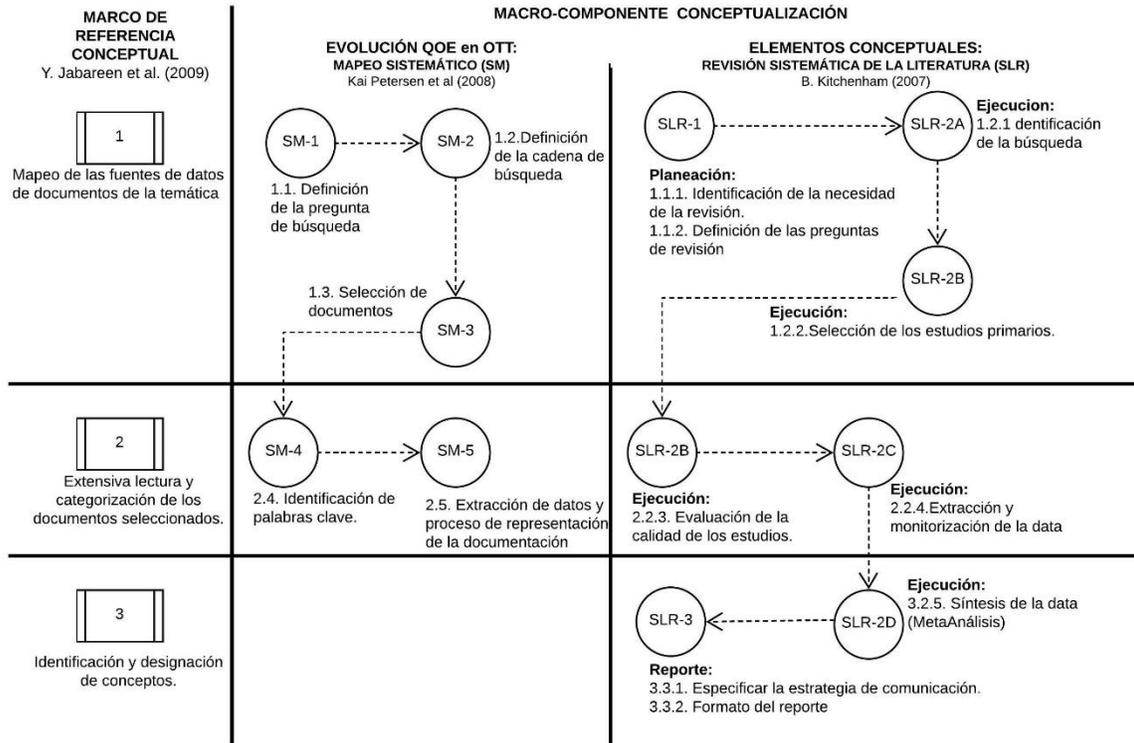


Figura 2.1.3. Módulos del modelo QoE para Servicios OTT.

- El módulo *Evolución QoE en OTT* ejecuta las etapas dispuestas por Kai Petersen et al. en [14] (Mapeo Sistemático - SM), y tiene como objeto entender el estado científico y tecnológico alrededor de la QoE para servicios OTT. Lo anterior con el ánimo de comprender en detalle el contexto y fenómeno de estudio para la definición de una meta específica dentro de la fase de comprensión del negocio.
- El módulo *Elementos conceptuales* ejecuta las etapas dispuestas por B. Kitchenham et al. en [59] (Revisión Sistemática de la Literatura - SLR), y tiene como objeto la definición de los elementos constituyentes en la estimación de la QoE para servicios OTT bajo condiciones de QoS. Lo anterior con el ánimo de identificar las condiciones de los elementos sobre los cuáles se obtendrán los datos para la construcción del modelo de estimación de la QoE.
- El módulo de *Modelo correlacional QoS-QoE* ejecuta las etapas dispuestas por CRISP-DM en [60] (Minería de Datos - DM) para cada uno de los perfiles definidos en el modelo, y tiene como objeto relacionar sus parámetros a partir de sus datos característicos, supuestos y restricciones (i.e. datos). Este módulo recibe como entrada las salidas de los módulos *Evolución QoE en OTT* y *Elementos conceptuales*. En efecto, la comprensión detallada del fenómeno de estudio (salida A de la Figura 2.1.3), y los elementos conceptuales o perfiles del modelo (salida B de la Figura 2.1.3), son necesarias para establecer la meta del módulo *Modelo correlacional QoS-QoE* e identificar los datos sobre los cuales se construye un modelo de estimación de la QoE.

Para mayor claridad con relación al uso de los referentes metodológicos empleados en el modelo QoE para servicios OTT, las figuras 2.1.4, 2.1.5, y 2.1.6 presentan cada una de las tareas de las fases de estas metodologías, indicando cuáles son adoptadas en correspondencia con las etapas de los módulos *Evolución QoE en OTT* y *Elementos conceptuales* (del macro-componente *Conceptualización*, representadas como SM y SLR, respectivamente), y del módulo *Modelo correlacional QoS-QoE* (del macro-componente *Operacional*, representadas como DM).



**Figura 2.1.4.** Relación de las etapas de los módulos del macro-componente Conceptualización (SM y SLR) y las fases de un marco de referencia conceptual<sup>1</sup>

En la Figura 2.1.4, la fase (1) del marco de referencia conceptual es instanciada a través de las etapas SM-1 a SM-3 del mapeo sistemático (i.e. SM), y de las etapas SLR-1 a SLR-2B de la revisión sistemática (i.e. SLR). La fase (2) del marco de referencia conceptual es instanciada a través de las etapas SM-4 a SM-5 del mapeo sistemático, y de las etapas SLR-2B a SLR-2C de la revisión sistemática. Finalmente, la fase (3) del marco de referencia conceptual es instanciada a través de las etapas SLR-2D a SLR-3 de la revisión sistemática.

<sup>1</sup> Las líneas punteadas especifican el orden de ejecución al interior de cada módulo.

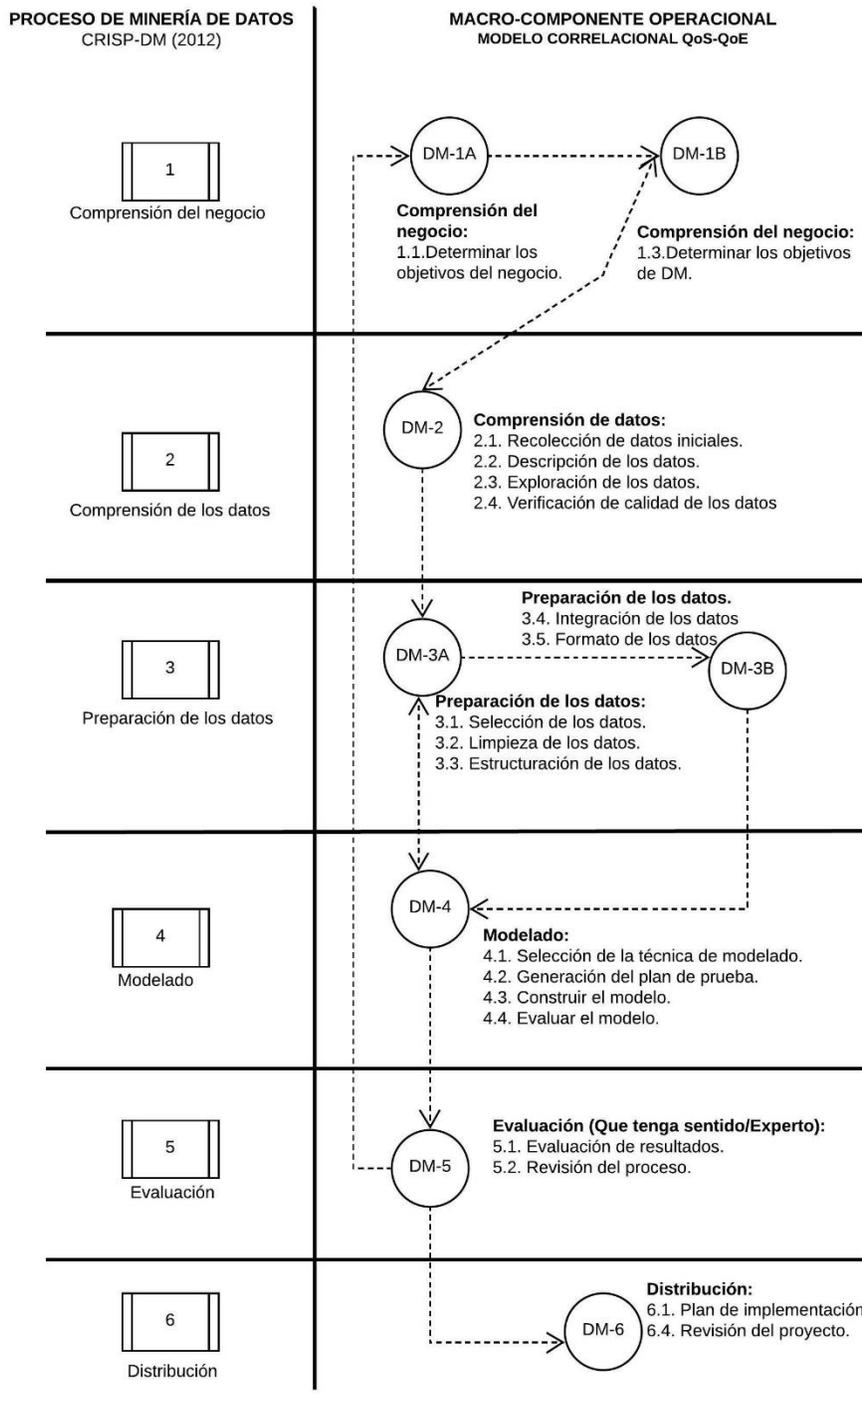


Figura 2.1.5. Relación de las etapas del macro-componente Operacional (DM) y las fases de CRISP-DM<sup>2</sup>

<sup>2</sup> Las líneas punteadas especifican el orden de ejecución al interior de cada módulo.

En la Figura 2.1.5, la fase uno (1) de CRISP-DM es representada por las etapas DM1-A y DM-1B del modelo. La fase dos (2) de CRISP-DM es representada por la etapa DM-2 del modelo. La fase tres (3) de CRISP-DM es representada por las etapas DM-3A y DM-3B del modelo. La fase cuatro (4) de CRISP-DM es representada por la etapa DM-4 del modelo. La fase cinco (5) de CRISP-DM es representada por la etapa DM-5 del modelo. La fase seis (6) de CRISP-DM es representada por la etapa DM-6 del modelo. El flujo de ejecución de cada etapa DM sigue lo dispuesto por la metodología referente (i.e. flujo de ejecución de CRISP-DM).

Para mayor claridad con relación al uso de CRISP-DM, la Figura 2.1.6 presenta cada una de las tareas de las fases de esta metodología, indicando cuáles son adoptadas en correspondencia con las etapas del módulo Modelo de correlación de perfiles (del macro-componente Operacional).

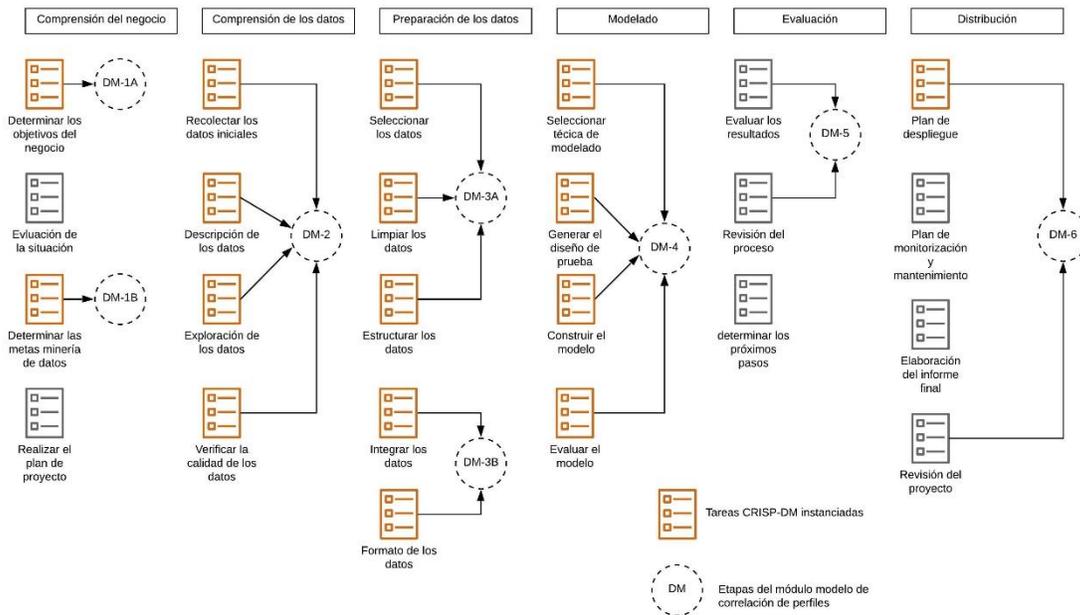


Figura 2.1.6. Relación de las etapas del macro-componente Operacional y las tareas de CRISP-DM.

## 2.2. DESCRIPCIÓN DEL PROCESO

El proceso de desarrollo del modelo QoE para servicios OTT tiene dos momentos. Un primer momento (A) encargado de la definición y conceptualización de los elementos del modelo en el contexto del aprovisionamiento de QoE para servicios OTT bajo condiciones de QoS; y un segundo momento (B) enfocado en la operación e implementación de los elementos conceptuales del modelo. El momento A está definido por las etapas SM y SLR; el momento B está definido por las etapas DM.

La Figura 2.2.1 presenta el proceso de ejecución de las etapas del modelo QoE para servicios OTT.

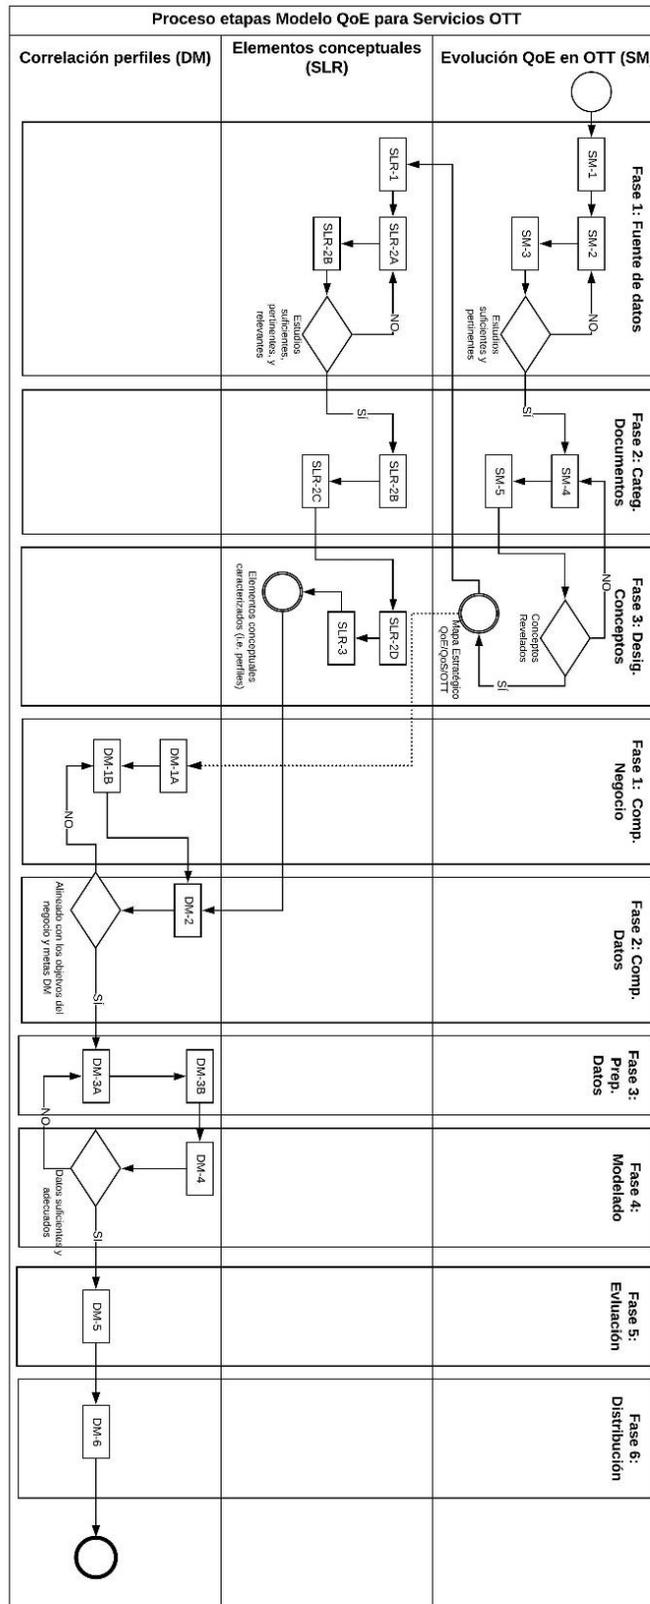


Figura 2.2.1. Proceso de ejecución de etapas del modelo QoE para servicios OTT

## 2.1.Momento A

El proceso inicia con la Etapa SM-1 del módulo Evolución QoE en OTT, y termina con la Etapa SLR-3 del módulo Elementos conceptuales. El proceso se realiza en dos iteraciones generales. La primera, ejecuta las etapas del módulo Evolución QoE en OTT de manera incremental; la segunda, ejecuta las etapas del módulo Elementos conceptuales de manera incremental. Los resultados de la primera iteración se utilizan como punto de partida para la siguiente con el ánimo de alcanzar una definición más precisa de los elementos conceptuales del modelo; si bien los referentes metodológicos instanciados en el macro-componente pueden seguirse de manera independiente, su configuración en el modelo genera un valor adicional en la obtención específica de los elementos conceptuales en la estimación de la QoE para servicios OTT.

Las salidas de cada iteración del macro-componente Conceptualización representan lo siguiente:

- La salida final de la iteración uno (i.e. etapa SM-5) es el mapa estratégico en el aprovisionamiento de la QoE para servicios OTT bajo condiciones de QoS.
- La salida final de la iteración dos (i.e. SLR-3) son los elementos conceptuales que integran el modelo QoE para servicios OTT.

Las salidas y resultados de cada etapa dentro de cada iteración son relacionadas en las figuras 2.2.2 y 2.2.3. El detalle de cada salida y producto está contenido en el Capítulo 3. Es importante resaltar que los resultados obtenidos en el momento A son las bases para las fases siguientes de un marco conceptual, en caso de que se aborde a futuro el desarrollo de uno para la estimación de la QoE.

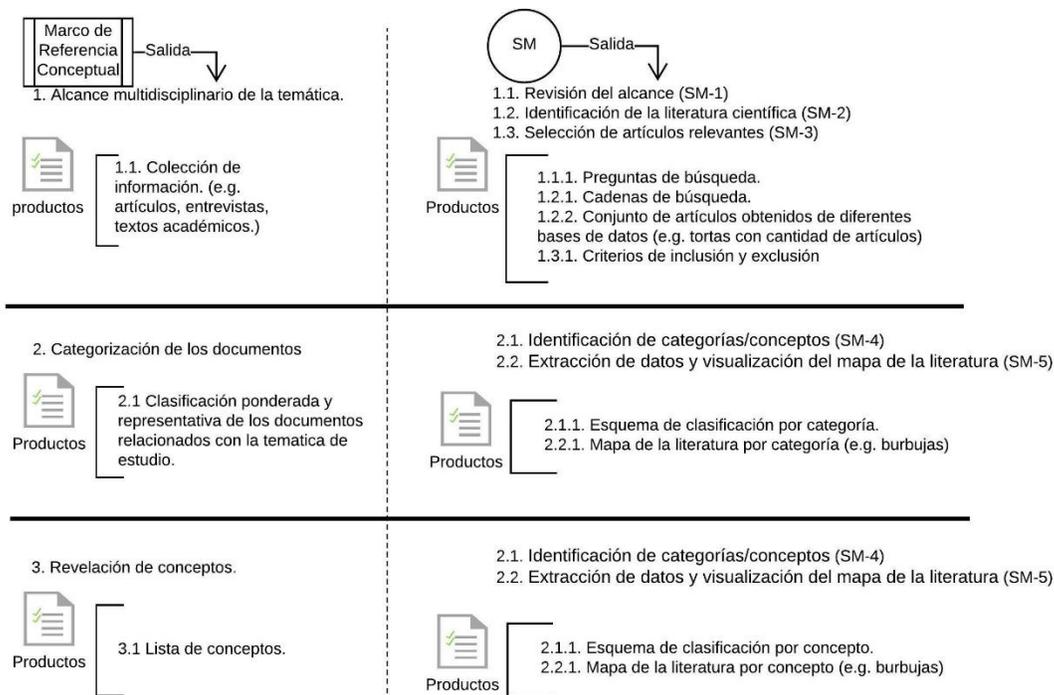


Figura 2.2.2. Correspondencias de las salidas del marco de referencia conceptual con las salidas del módulo Evolución QoE en OTT – SM

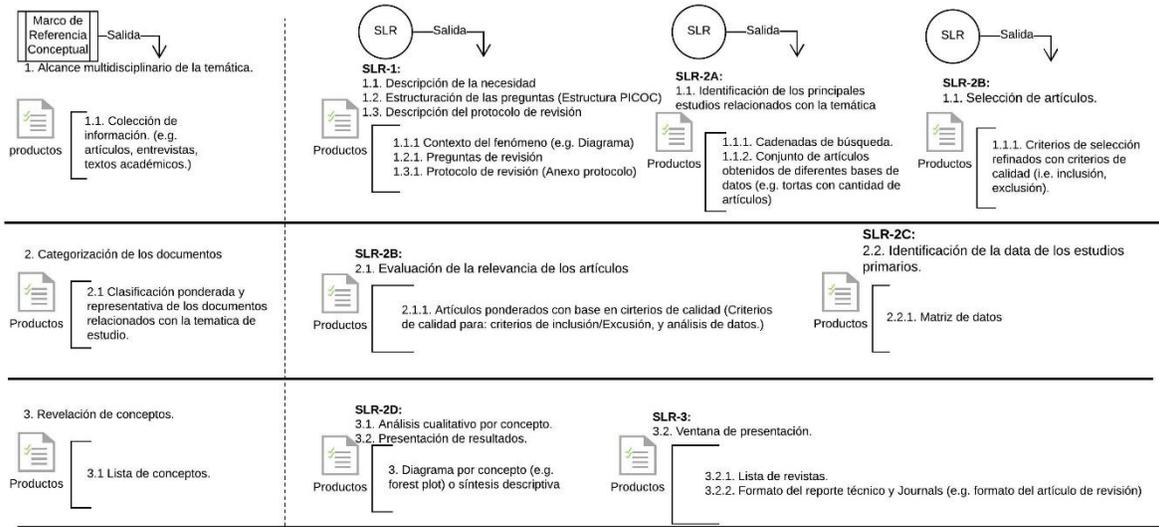


Figura 2.2.3. Correspondencias de las salidas del marco de referencia conceptual con las salidas del módulo Elementos conceptuales – SLR

## 2.2.Momento B

El proceso inicia con la Etapa DM-1A y termina con la Etapa DM-6 del módulo Modelo correlacional QoS-QoE. Este proceso se realiza en tres iteraciones específicas, cada una de ellas representada por el desarrollo incremental de cada uno de los perfiles del modelo.

Si bien el referente metodológico instanciado en el macro-componente puede seguirse de manera independiente, su configuración en el modelo genera un valor adicional en el desarrollo de los modelos de datos de los perfiles; esto es: la etapa DM-1A recibe como entrada el resultado final del módulo Evolución QoE en OTT (i.e. mapa estratégico QoE/QoS/OTT) con el ánimo de entender con mayor claridad el contexto de cada perfil del modelo; mientras que la etapa DM-2 recibe como entrada externa el resultado final del módulo Elementos Conceptuales (i.e. perfiles del modelo) con el ánimo de comprender los datos y elementos representativos de los perfiles del modelo.

Las salidas de cada iteración del macro-componente Operacional implementado por el módulo Modelo correlacional QoS-QoE representan lo siguiente:

- La salida final de la iteración uno (i.e. Etapa DM-2) es el perfil de servicio del modelo QoE para servicios OTT operado e implementado. Como entrada, el perfil de servicio recibe la información del tráfico de un nodo monitorizado que fue recolectada de acuerdo con los hallazgos del módulo Evolución QoE en OTT; como salida, el perfil de servicio entrega un conjunto de datos estructurado con sus descriptores de comportamiento de un flujo en una conexión bidireccional entre un usuario y sus servicios consumidos.
- La salida final de la iteración dos (i.e. Etapa DM-4) es el perfil de usuario del modelo QoE para servicios OTT operado e implementado. Como entrada, el perfil de usuario recibe los datos de percepción de la calidad del servicio luego de su consumo; como salida, el perfil de usuario entrega un conjunto de datos estructurado que relaciona la calidad percibida por el usuario a partir de sus preferencias de consumo de servicios OTT.
- La salida final de la iteración tres (i.e. Etapa DM-6) es el perfil paramétrico del modelo QoE para servicios OTT operado e implementado. Como entrada, el perfil paramétrico recibe los dos conjuntos de datos estructurados entregados por el perfil de servicio y perfil de usuario, y en su salida entrega

un modelo de estimación del nivel de QoE a partir de unas condiciones de QoS en el tráfico de red una Telco.

El producto resultado de cada iteración fue pensado de manera global y modular en caso de requerir modelos independientes que respondan a metas de negocio específicas. Sin embargo, la implementación de las fases en cada iteración está en función de la necesidad particular del operador; esto es: monitorizar la QoE para el aprovisionamiento de servicios OTT dentro de su infraestructura de red.

Finalmente, las salidas, resultados y fases implementadas de cada etapa dentro de cada iteración, son relacionadas en la Figura 2.2.4. El detalle de cada salida, producto y fase está contenido en el Capítulo 4.

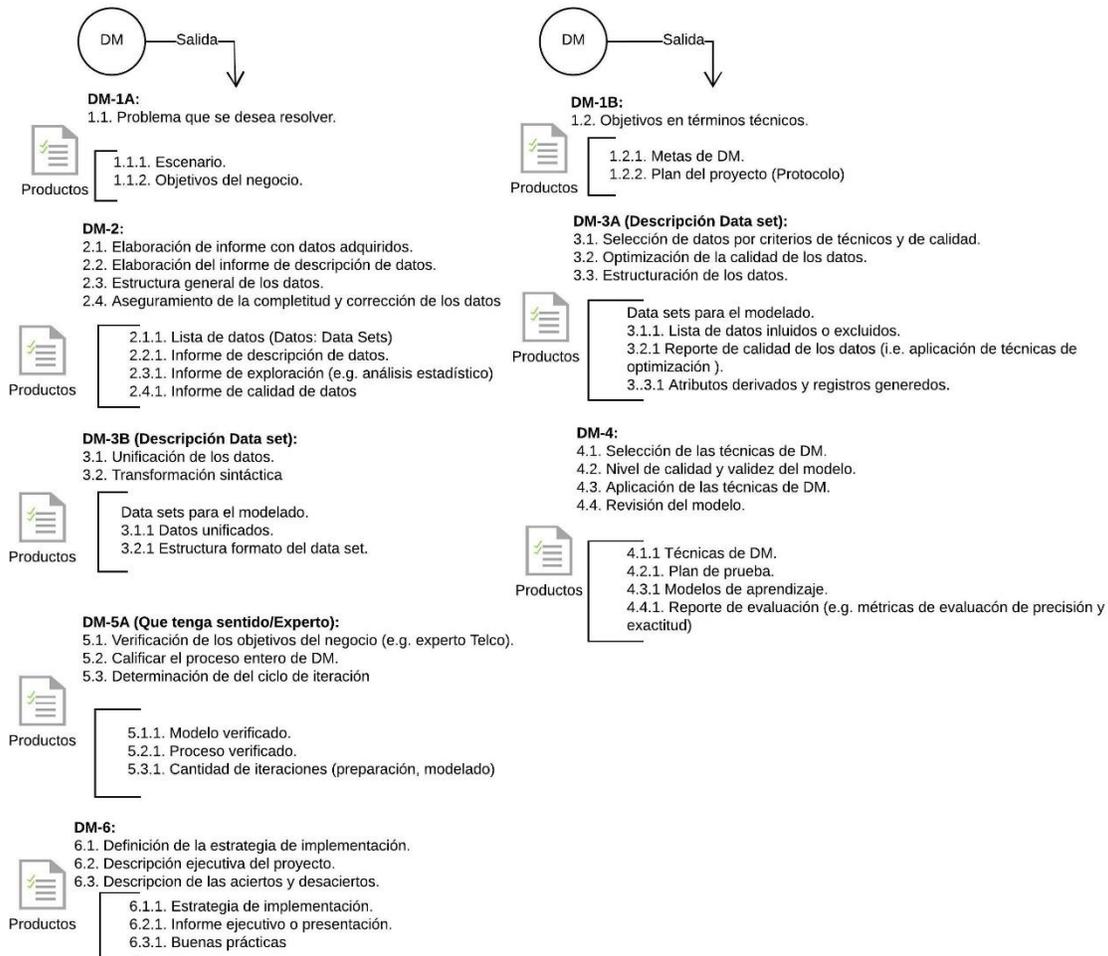


Figura 2.2.4. Correspondencias de las salidas de CRISP-DM con las salidas del módulo Modelo de correlación de perfiles – DM

## 2.3. RECAPITULACIÓN

En este capítulo se describió el modelo de la QoE para servicios OTT a partir de la definición de los macro-componentes que lo conforman. Primero, un macro-componente Conceptualización centrado en analizar a profundidad el estado tecnológico y científico alrededor del aprovisionamiento de la QoE en el consumo de servicios OTT, y en definir los elementos conceptuales que se requieren en la monitorización de la QoE al interior de la infraestructura de red de una Telco. Segundo, un macro-componente Operacional enfocado en la construcción de un modelo basado en datos para la estimación de un nivel de QoE a partir de las condiciones de QoS entregadas por una Telco al momento de consumir servicios OTT por parte de sus usuarios.

Para el desarrollo de cada macro-componente se tomaron como referentes las metodologías de Jabareen [61] y CRISP-DM [60]. La primera, instanciada por medio de la adaptación de las fases dispuestas por Petersen en el mapeo sistemático [14] y por Kitchenham en la revisión sistemática de la literatura [59]; la segunda, instanciada por las tareas definidas para cada fase del proceso de proyectos en minería de datos.

En síntesis, la estructura del modelo QoE para servicios OTT implementada en dos momentos (A y B), permite la obtención de base teórica y conceptual alrededor de la QoE, la definición de los perfiles del modelo, y la generación de un modelo de estimación del nivel de la QoE para la monitorización de esta dentro de la infraestructura de una Telco.

## CAPÍTULO 3. MACRO-COMPONENTE CONCEPTUALIZACIÓN

En el presente capítulo se analizará el estado de la evolución de la ciencia en el área de QoE y se definirán los elementos conceptuales del Modelo de QoE para servicios OTT. Para ello, el protocolo de mapeo y revisión es aplicado de acuerdo con las indicaciones expuestas en detalle en el Anexo B, en tanto que en este capítulo se presentarán los resultados del proceso. El mapeo sistemático y la revisión sistemática operan en conjunto para el desarrollo del macro-componente Conceptualización, y establecen una base conceptual sobre la cual se define el modelo de estimación del nivel de QoE. En particular, el mapeo sistemático da cuenta de las condiciones de aprovisionamiento de la QoE, y la revisión sistemática da cuenta de las características de cada uno de los elementos conceptuales representados como perfiles en el modelo QoE para servicios OTT.

Si bien estos referentes metodológicos son empleados en la construcción del estado del arte en la presentación del contexto de estudio (Capítulo 1), la finalidad dentro del desarrollo de este macro-componente es diferente. Para el estado del arte, se busca una visión general de las áreas temáticas QoE, QoS, y OTT, mientras que en el desarrollo del macro-componente Conceptualización se buscan las condiciones específicas en el aprovisionamiento de la QoE para servicios OTT bajo criterios de QoS del operador de telecomunicaciones. No obstante, el estado del arte puede ser considerado como una fase cero que permite encaminar la definición del modelo QoE para servicios OTT

La implementación del macro-componente Conceptualización sigue las indicaciones y condiciones establecidas por el protocolo conceptual del modelo, explicado en el Anexo B. Para el módulo Evolución QoE en OTT se procede con la parte 1 del protocolo, y para el módulo Elementos conceptuales se procede con la parte 2 del protocolo.

### 3.1. MÓDULO EVOLUCIÓN QOE EN OTT

#### 3.1.1. Definición de las preguntas de búsqueda (SM-1).

Para analizar el estado de evolución en el marco de la QoE para servicios OTT se deben definir las preguntas que orientarán la búsqueda y análisis de los estudios científicos; esto es:

- ¿Cuál ha sido la evolución en la ciencia alrededor de la QoE en la prestación de servicios OTT?
- ¿Qué temas específicos de investigación están siendo atendidos alrededor de la QoE para servicios OTT?
- ¿Quiénes son los autores más relevantes alrededor de la QoE?
- ¿Cuáles son los desafíos o limitaciones alrededor de la QoE en el aprovisionamiento de servicios OTT?

La Tabla 3.1.1 relaciona la salida de la etapa SM-1 con los productos generales de la etapa y particulares del módulo Evolución QoE en OTT del modelo.

Tabla 3.1.1. Productos de la etapa SM-1 y del módulo Evolución QoE en OTT.

Salidas SM-1	Producto general de la etapa	Producto particular del módulo
Revisión del alcance	Preguntas de búsqueda	Preguntas de QoE para servicios OTT

#### 3.1.2. Definición de la cadena de búsqueda (SM-2)

La cadena de búsqueda depende de las preguntas formuladas y está estructurada según la configuración soportada por las librerías digitales. Las librerías digitales han sido seleccionadas teniendo en cuenta el estudio realizado por Michael Gusenbauer en [62].

La cadena de búsqueda ha sido formulada de manera general con el ánimo de abarcar la mayor cantidad de documentación científica que tenga el potencial de explicar el fenómeno de estudio. Sin embargo, el proceso de análisis puede llegar a ser tedioso y complejo debido a la elevada cantidad de estudios hallados entre el periodo seleccionado de análisis. En consecuencia, una estrategia semi-automática ha sido llevada a cabo con el objeto de mejorar la capacidad de procesamiento y análisis de los trabajos encontrados, utilizando la herramienta SciMAT; esta es presentada por M.J. Cobo et al. en [63].

Las tablas 3.1.2 y 3.1.3 presentan los resultados obtenidos en cada una de las librerías digitales consultadas (i.e. Total de estudios por librería digital)

**Tabla 3.1.2. Cantidad estudios por librería digital**

<b>Cadena de búsqueda: "Quality of Experience" OR "QoE".</b>					
<b>Periodo de búsqueda: 20 años</b>					
IEEE	Science Direct	Base	ACM	Wiley	WoS
17.237	560.513	2.709	276.079	663.964	184.509
Total					
1.705.011					

Luego de evaluar la pertinencia de los artículos de acuerdo con los criterios de inclusión o exclusión, se refina la cadena de búsqueda con el ánimo de filtrar los estudios científicos (i.e. condicional de la salida SM-3); esto es:

**Tabla 3.1.3. Cantidad estudios por librería digital con cadena de búsqueda delimitada.**

<b>Cadena de búsqueda: ("Quality of Experience" OR "QoE") AND (QoS OR OTT).</b>				
<b>Periodo de búsqueda: 20 años</b>				
Science Direct	Base	ACM	Wiley	WoS
6.552	790	8.056	5.068	2.462
Total				
22.937				

Para la obtención detallada de los metadatos de los estudios encontrados, se procede con la ejecución del paso uno del flujo de trabajo del mapeo de la ciencia expuesto en [63] (i.e. recuperación de los datos). Los metadatos son el conjunto de datos que describen el contenido de los estudios científicos (e.g. autores, título, palabras clave, citas).

La Tabla 3.1.4 relaciona la salida de la etapa SM-2 con los productos generales de la etapa y particulares del módulo Evolución QoE en OTT del modelo.

**Tabla 3.1.4. Productos de la etapa SM-2 y del módulo Evolución QoE en OTT.**

Salidas SM-2	Producto general de la etapa	Producto particular del módulo
Identificación de la literatura científica	Cadena de búsqueda	Tablas 3.1.2 y 3.1.3
	Conjunto de artículos obtenidos de diferentes librerías digitales	Tablas 3.1.2 y 3.1.3

### 3.1.3. Selección de documentos (SM-3)

La selección de documentos permite filtrar los estudios en relación con el aporte al entendimiento de fenómeno de estudio. Para ello, se han definido criterios de inclusión y de exclusión; a saber:

**Criterios de inclusión.**

- Publicaciones científicas a partir del año 2000.
- La ventana de observación debe ser por lo menos de 10 años.
- Las publicaciones científicas comprenden: libros, capítulos de libros, revistas y magazines, conferencias, artículos de datos.
- Publicaciones científicas que abarquen el modelado, medición, gestión, aprovisionamiento y estimación de la QoE.

**Criterios de exclusión.**

- Literatura gris y técnica especializada (e.g. cursos, videos, trabajos de opinión).
- Publicaciones científicas sin citaciones (no aplica para estudios con 4 años antes del inicio de la revisión).
- Publicaciones científicas en su versión no extendida para documentos duplicados.

Para la depuración de los estudios, se procede con la ejecución del paso dos del flujo de trabajo del mapeo de la ciencia expuesto en [63] (i.e. pre-procesamiento)

La Tabla 3.1.5 relaciona la salida de la etapa SM-3 con los productos generales de la etapa y particulares del módulo Evolución QoE en OTT del modelo.

**Tabla 3.1.5.** Productos de la etapa SM-3 y del módulo Evolución QoE en OTT.

Salidas SM-3	Producto general de la etapa	Producto particular del módulo
Selección de artículos relevantes	Criterios de inclusión y de exclusión	Criterios para el tipo de publicaciones, periodo de estudio e impacto

**3.1.4. Identificación de palabras clave (SM-4)**

La identificación de las palabras clave que relacionan cada uno de los estudios científicos se realiza con los pasos de pre-procesamiento y extracción de la red expuestos por M.J. Cobo et al. en [63]; esto es:

**3.1.4.1. Pre-procesamiento:**

La selección de artículos se realiza con base en los criterios de inclusión y exclusión, la eliminación de estudios duplicados, y nivel de pertinencia de acuerdo con el fenómeno de estudio (e.g. análisis del tema a través de la lectura del resumen del estudio).

**3.1.4.2. Extracción de la red:**

Se procede con la definición de la unidad de análisis para construir la red que relaciona y posiciona los estudios científicos en el cuadrante del mapa de la ciencia expuesto por M.J. Cobo et al. en [64]; esto es, la selección de la relación “*co-ocurrencia*” para la unidad de análisis de términos o palabras compuestas (i.e. Categorías conceptuales). Adicionalmente, las redes son construidas por periodos de tiempo con el ánimo de observar la evolución del fenómeno de estudio; para este caso, cuatro (4) periodos han sido definidos (2000-2005, 2006-2010, 2011-2015, y 2016-2020)

**Unidad de análisis – Categorías conceptuales**

La unidad de análisis seleccionada para la construcción de los nodos de la red fue la elaboración de las categorías conceptuales, las cuales representan una asociación de palabras y conceptos comunes entre los estudios científicos. Para ello, es necesario el conocimiento del fenómeno para lograr una mejor agrupación de las palabras representativas obtenidas de los metadatos de los estudios consultados.

Para la generación de las categorías conceptuales a partir de las palabras representativas de los estudios científicos, debe llevarse a cabo un análisis de equivalencia. En este caso, el criterio de equivalencia es la similitud de las palabras por su sintaxis, y luego la similitud de palabras de acuerdo con su semántica. Aquí, el conocimiento del dominio es crucial para la agrupación apropiada de las palabras en los respectivos grupos o categorías conceptuales.

La Tabla 3.1.6 presenta el total de palabras obtenidas de los metadatos para la librería WoS, la cual fue objeto de análisis y procesamiento para el módulo Evolución QoE en OTT, y la totalidad de las categorías conceptuales generadas.

**Tabla 3.1.6.** Grupos conceptuales del módulo Evolución QoE en OTT

Total de palabras en el archivo WoS	Total de categorías conceptuales	Total de palabras eliminadas
5.381 palabras representativas de los estudios científicos.	152 categorías que agrupan 3.818 palabras representativas, e.g., <ul style="list-style-type: none"> <li>• QoS con 158 palabras.</li> <li>• QoE con 84 palabras.</li> <li>• OTT con 21 palabras.</li> </ul>	1.563

La Tabla 3.1.7 relaciona la salida de la etapa SM-4 con los productos generales de la etapa y particulares del módulo Evolución QoE en OTT del modelo.

**Tabla 3.1.7.** Productos de la etapa SM-4 y del módulo Evolución QoE en OTT.

Salidas SM-4	Producto general de la etapa	Producto particular del módulo
Clasificación de artículos	Esquema de clasificación por categoría o palabras clave (Grupos conceptuales)	Total de grupos conceptuales (ver Tabla 3.1.6)

### 3.1.5. Extracción de datos y representación de la documentación (SM-5)

La extracción de datos permite la captura, análisis, y síntesis de los elementos clave que asocian cada categoría conceptual construida a partir de la detección de las palabras clave. Para ello, la herramienta SciMAT [65] aprovecha las ventajas de algoritmos de clustering y de las medidas de centralidad y densidad expuestas por Callon et al. [66].

Las actividades para la extracción son: selección de periodos (i.e. 4 periodos definidos para el intervalo 2000 a 2020), selección de unidad de análisis (i.e. categorías conceptuales), selección del método de reducción de datos (i.e. frecuencia mínima de 3 por periodo), selección del tipo de matriz (i.e. co-ocurrencia), selección del método de reducción de la red (i.e. valor mínimo de reducción 3 por periodo), selección de la medida de normalización (i.e. índice de equivalencia), aplicación del algoritmo de clustering (i.e. de centros simples), selección de los documentos de mapeo (i.e. primario y secundario), selección de medidas de calidad (i.e. índice h, promedio de citas), selección de medidas del mapa longitud (i.e. índice de equivalencia para el mapa superposición y el de evolución), construcción del mapa de la ciencia.

En esta etapa se ejecutan los pasos de normalización, mapeo, análisis, visualización, e interpretación expuestos por M.J. Cobo et al., en [63].

#### 3.1.5.1. Visualización de las categorías conceptuales para el módulo Evolución QoE en OTT

Las figuras 3.1.1. y 3.1.2 presentan el mapa de superposición y longitudinal, respectivamente. El mapa de superposición permite visualizar la cantidad de categorías conceptuales que tienen lugar en cada uno de los periodos definidos para el análisis (e.g. para el periodo 2006-2010, de las 76 categorías conceptuales del periodo anterior, 70 categorías se mantienen, 53 categorías nuevas surgen a partir del empleo de palabras representativas de los estudios, mientras que 2 categorías desaparecen para el siguiente periodo). El mapa longitudinal permite visualizar la evolución de los tópicos de investigación durante los periodos de análisis definidos (i.e. la evolución de las categorías conceptuales).

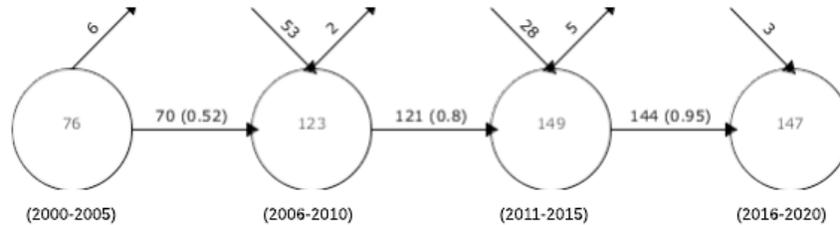


Figura 3.1.1. Mapa de superposición para el módulo Evolución QoE en OTT.

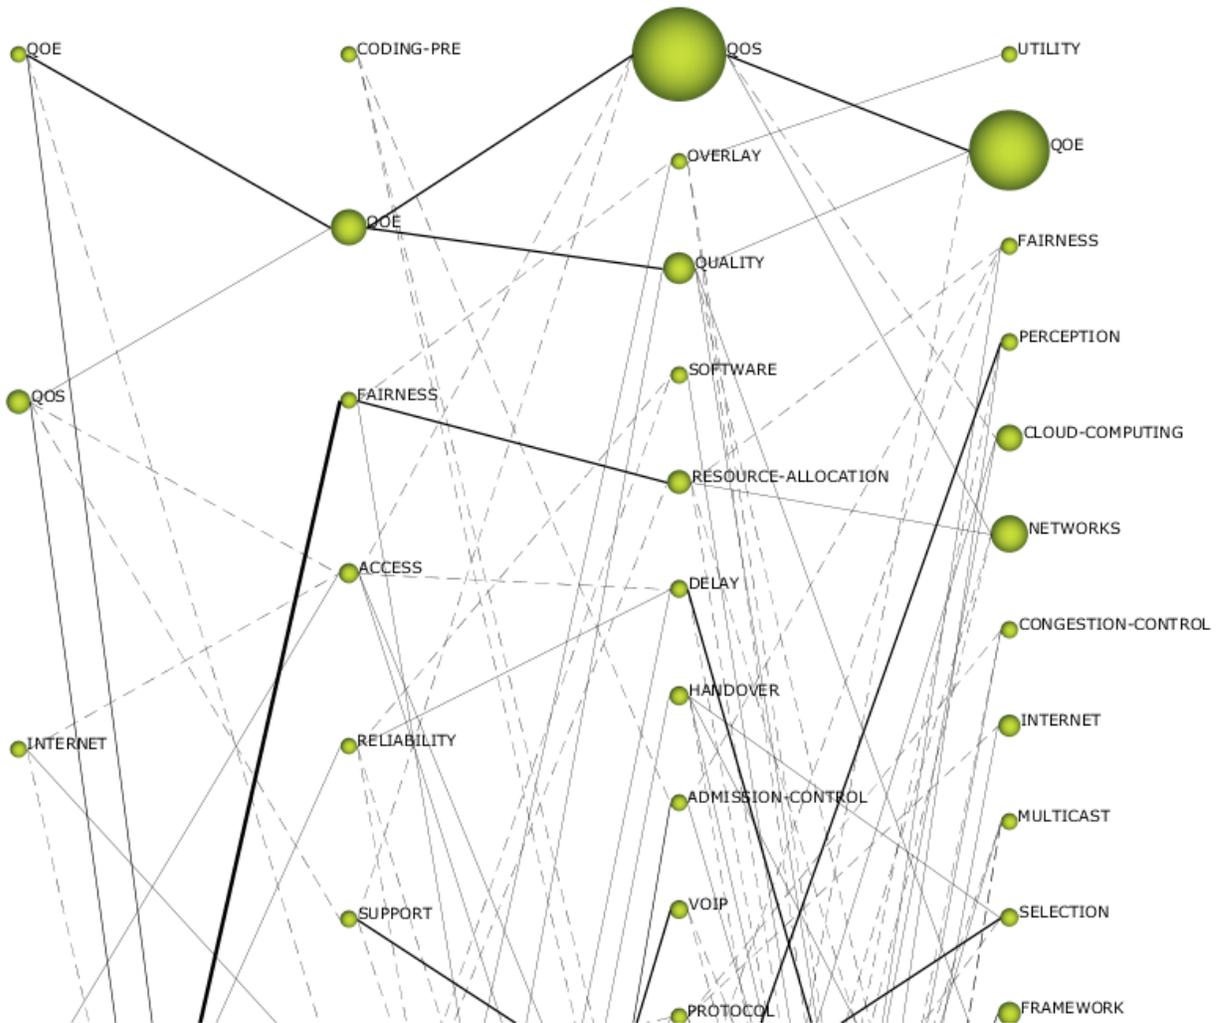
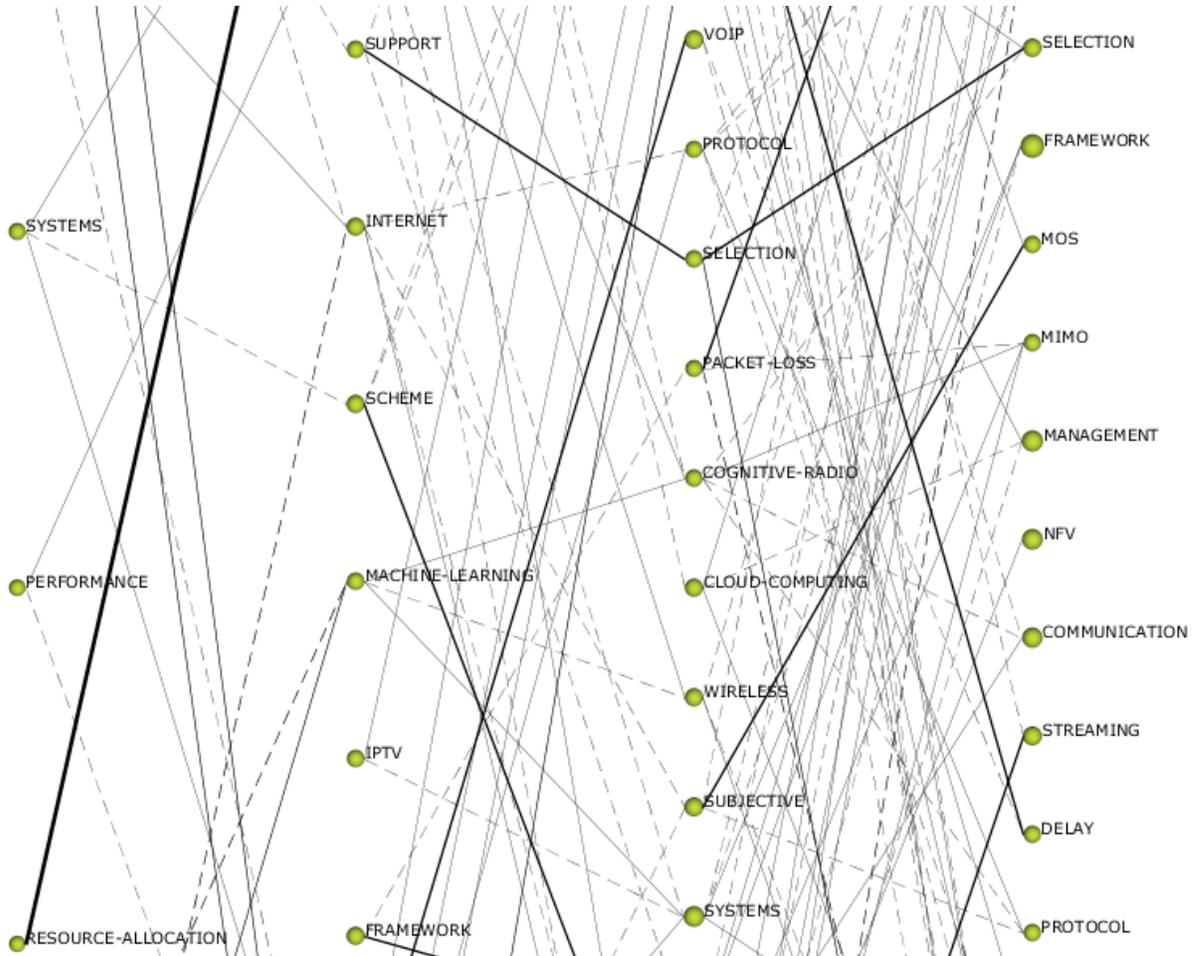


Figura 3.1.2. Mapa longitudinal para el módulo Evolución QoE en OTT - Parte I



**Figura 3.1.2.** Mapa longitudinal para el módulo Evolución QoE en OTT – Parte II

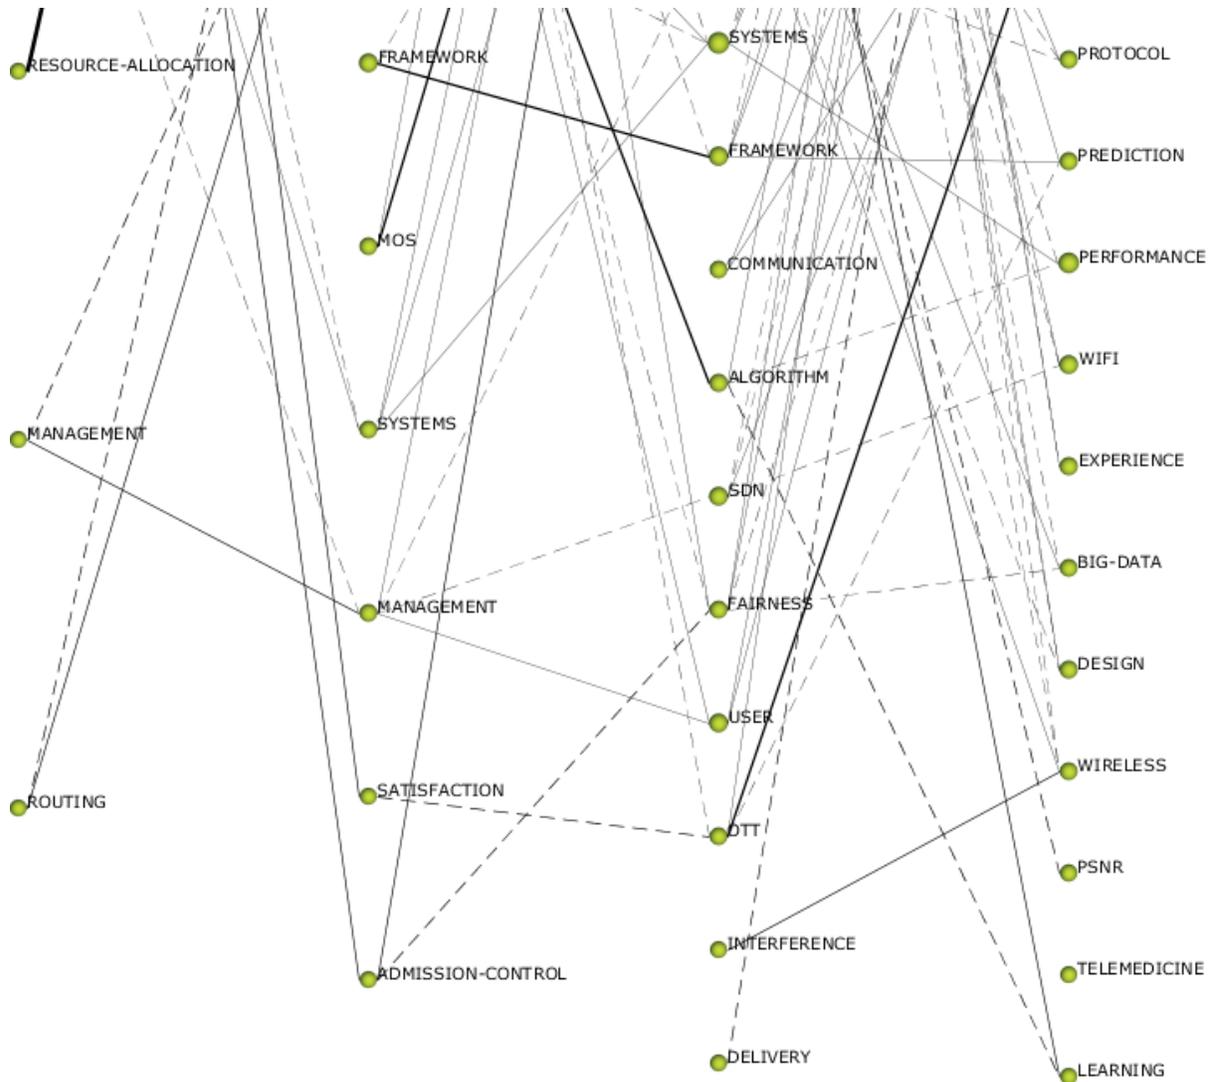
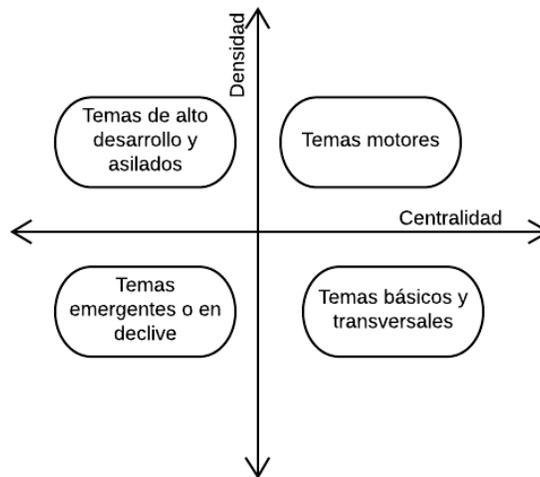


Figura 3.1.2. Mapa longitudinal para el módulo Evolución QoE en OTT – Parte III

Las líneas del mapa longitudinal permiten analizar la fortaleza de la relación entre las categorías conceptuales; la línea continua representa una relación teórica, donde la categoría conceptual se mantiene por periodos de análisis o que una categoría es parte de otra; la línea discontinua representa que las categorías conceptuales comparten elementos entre ellas o que en su estructura interna tienen elementos equivalentes. Finalmente, el grosor de la línea determina la proporcionalidad del valor de similitud de las categorías conceptuales.

La interpretación de los mapas se hace con base en el diagrama estratégico por cuadrante expuesto por M.J. Cobo et al. en [64] (Ver Figura 3.1.3). Esto es:

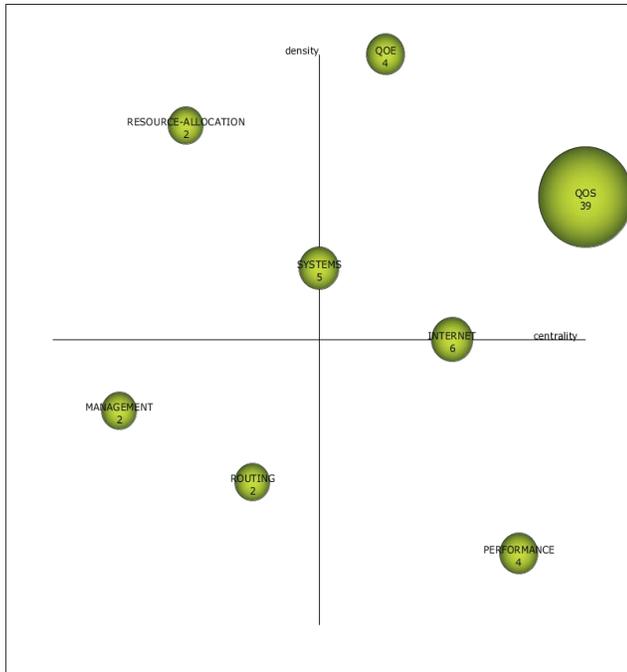
- Temas motores: Categorías conceptuales bien desarrolladas e importantes para estructurar el fenómeno de estudio (i.e. QoE en OTT).
- Temas de alto desarrollo y aislados: Categorías conceptuales bien desarrolladas, pero con importancia secundaria en la estructura del fenómeno de estudio.
- Temas emergentes o en declive: Categorías conceptuales débilmente desarrolladas o marginales. Esto se traduce en categorías conceptuales emergentes o categorías conceptuales por desaparecer.
- Temas básicos y transversales: Categorías conceptuales importantes para estructurar el fenómeno de estudio, pero no ampliamente desarrolladas.



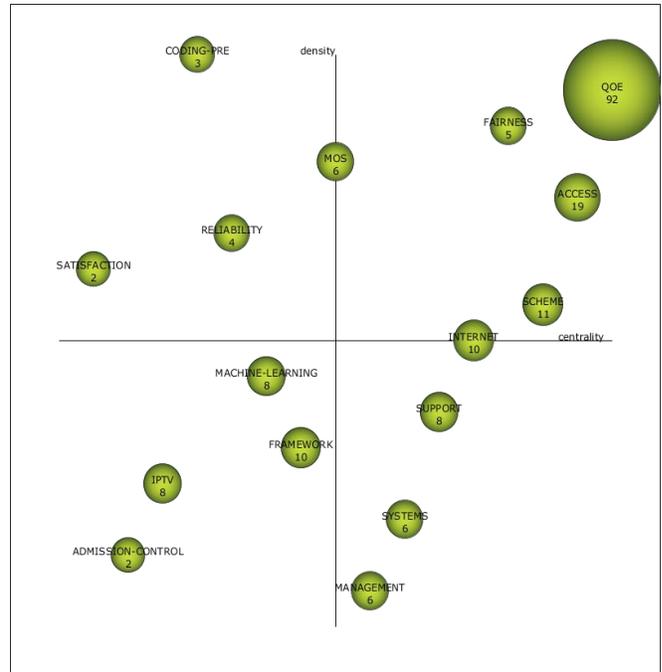
**Figura 3.1.3.** Diagrama estratégico.  
**Fuente:** Tomado de [64].

Los ejes del cuadrante representan las medidas de relevancia y pertinencia para las categorías conceptuales en términos de su avance propio y aporte al desarrollo del fenómeno de estudio; es decir, la centralidad representa la fortaleza de la relación entre las categorías conceptuales y el fenómeno de estudio. Por su parte, la densidad representa la fortaleza del desarrollo de la categoría a partir del agrupamiento y desarrollo de las palabras representativas que la constituyen.

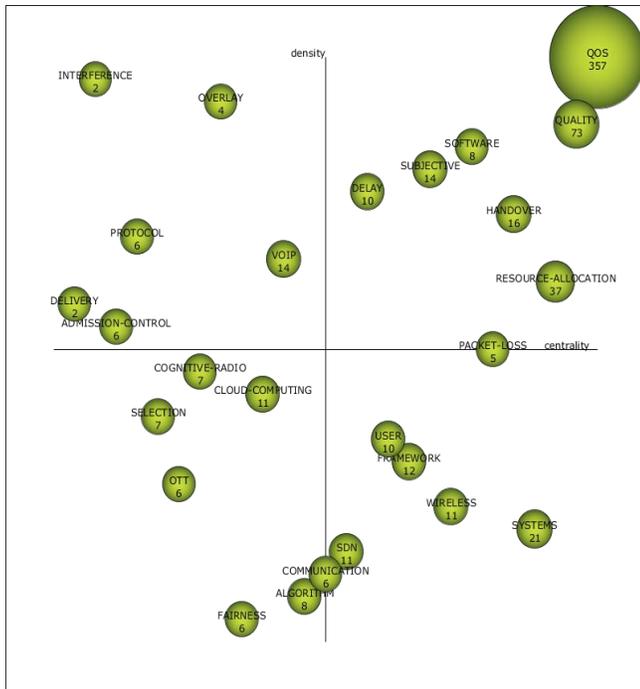
La Figura 3.1.4 presenta, por periodos de tiempo, el avance y desarrollo de las categorías conceptuales para el módulo Evolución QoE en OTT. Adicionalmente, la Figura 3.1.5 expone la relación entre categorías conceptuales que permite comprender el aporte científico de la categoría al fenómeno de estudio.



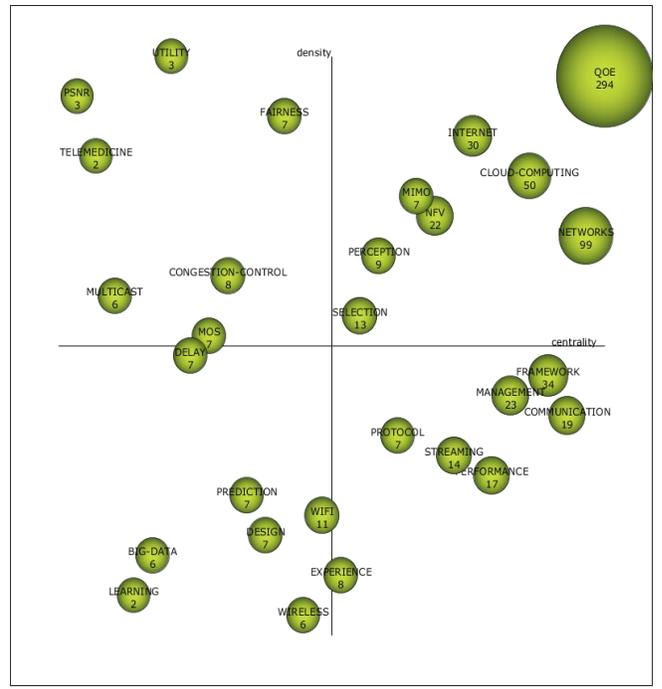
a. 2000 a 2005



b. 2006 a 2010



c. 2011 a 2015



d. 2016 a 2020

Figura 3.1.4. Diagrama estratégico por periodos de análisis para el módulo Evolución QoE en OTT.

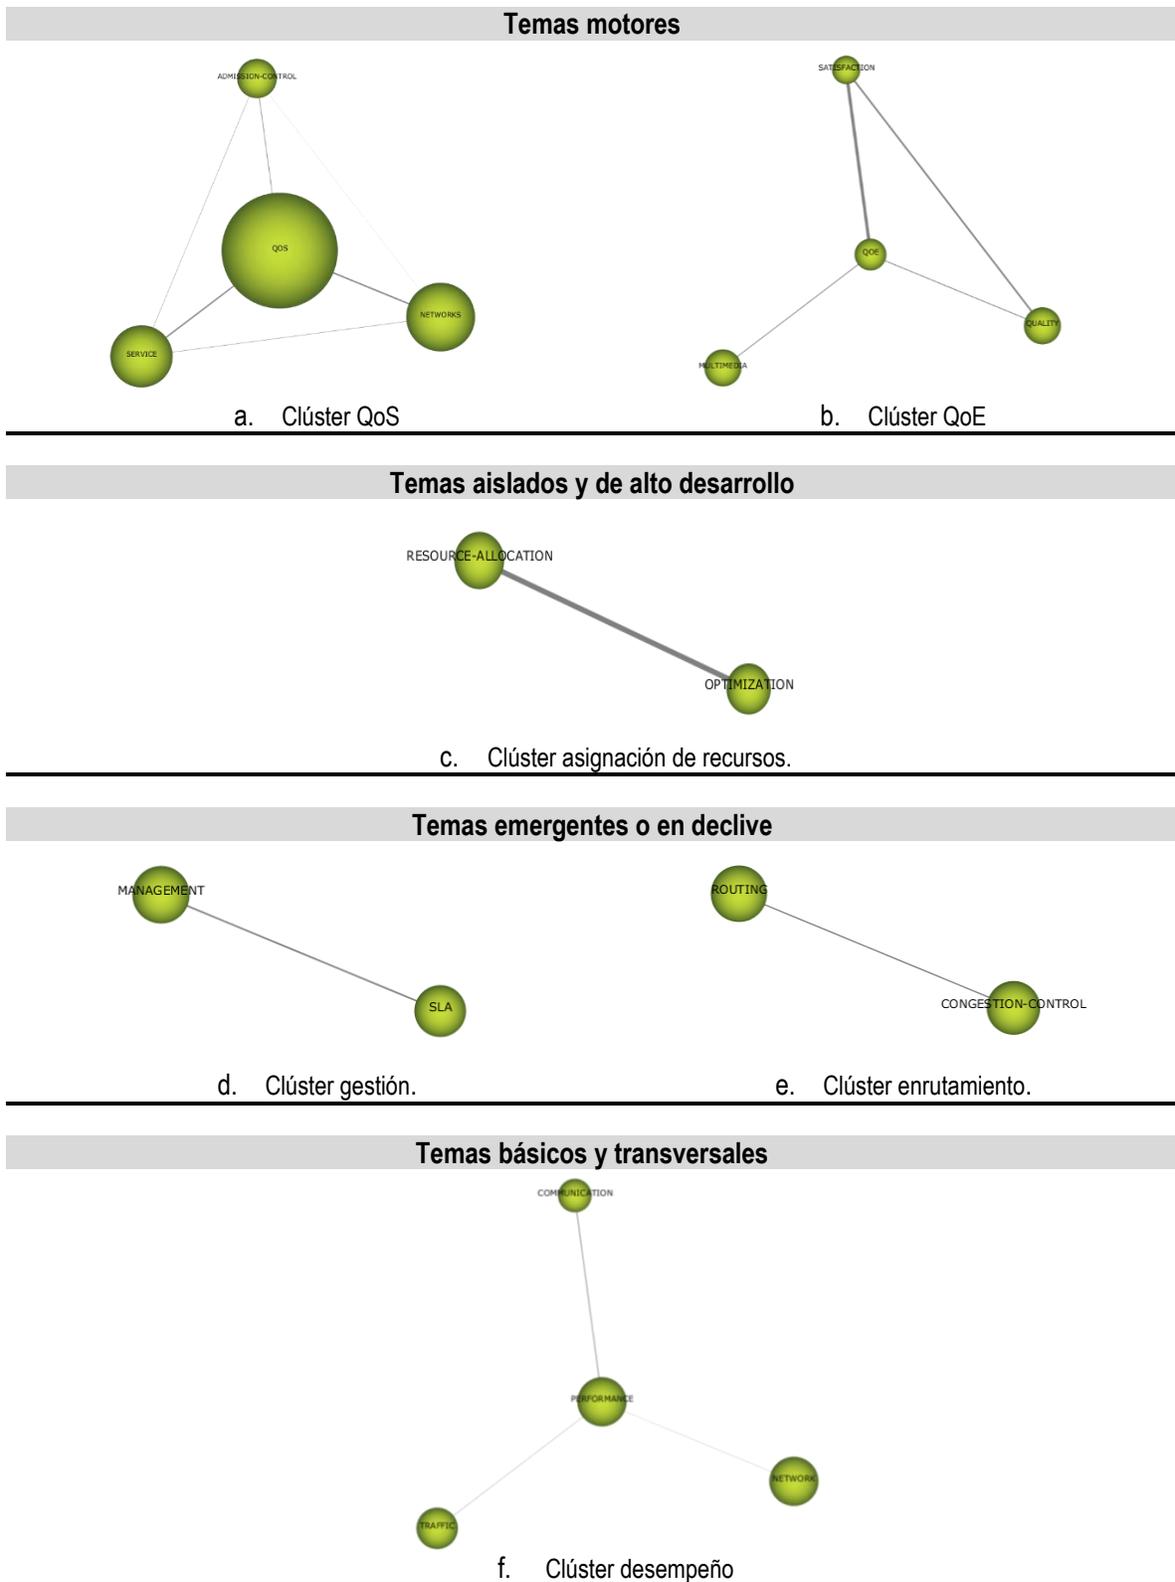
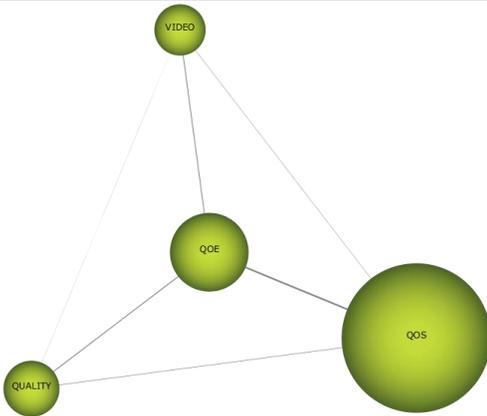
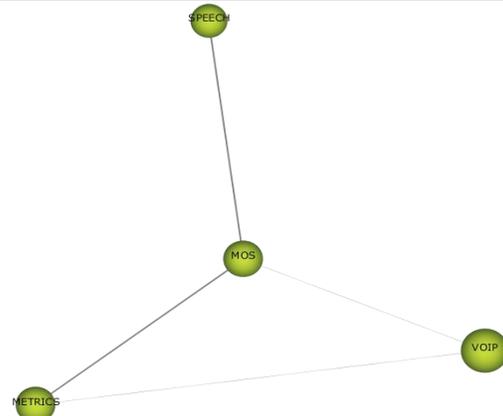


Figura 3.1.5. Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte I (2000 a 2005)

**Temas motores**



a. Clúster QoE

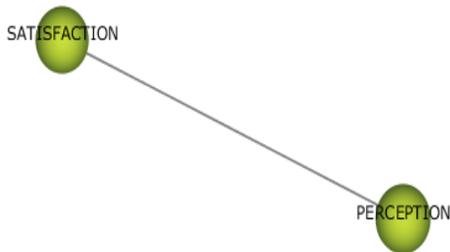


b. Clúster MOS

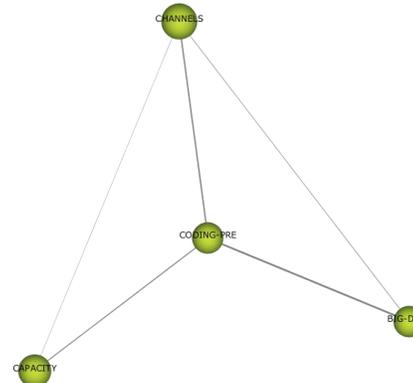


c. Clúster de justicia

**Temas aislados y de alto desarrollo**

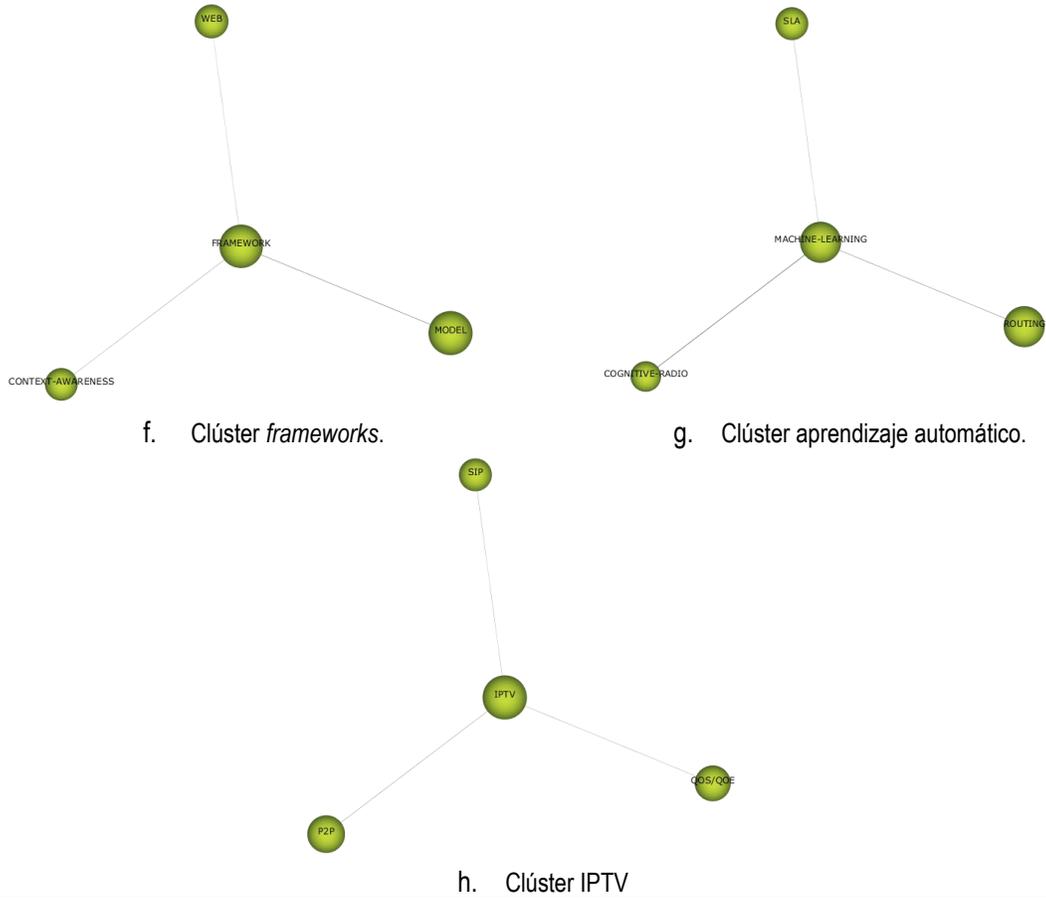


d. Clúster satisfacción



e. Clúster codificación

**Temas emergentes o en declive**



**Temas básicos y transversales**

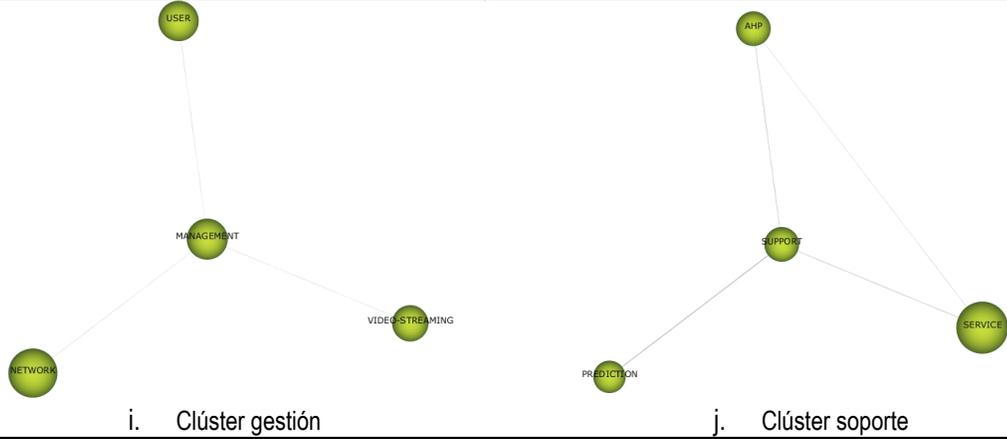
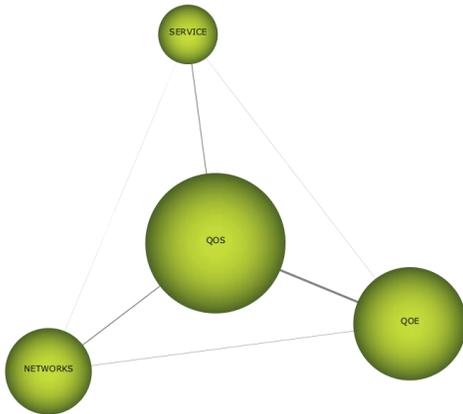
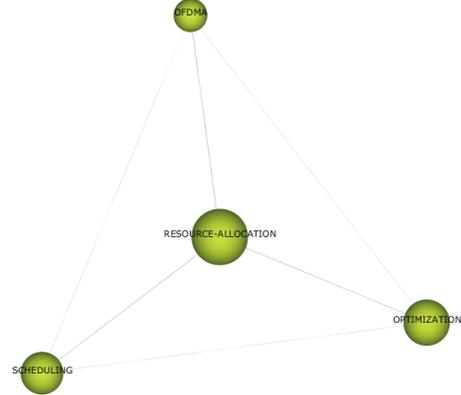


Figura 3.1.5. Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte II (2006 a 2010)

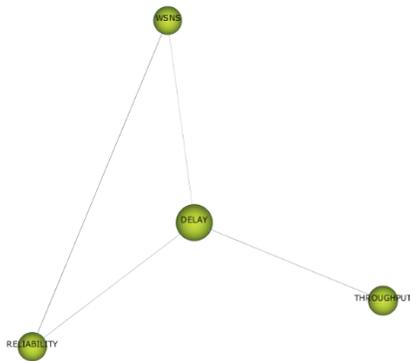
**Temas motores**



a. Clúster QoS



b. Clúster asignación de recursos

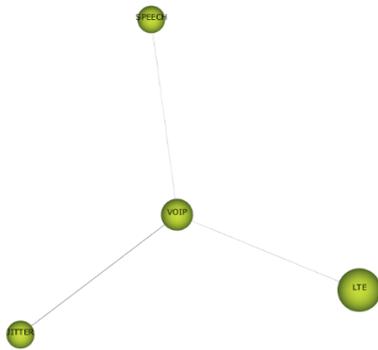


c. Clúster retardo

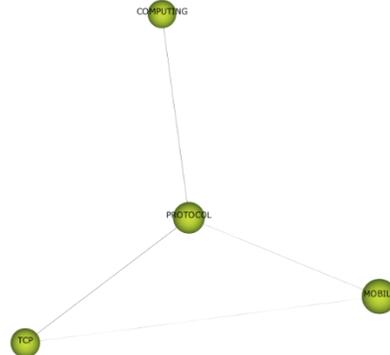


d. Clúster pérdida paquetes

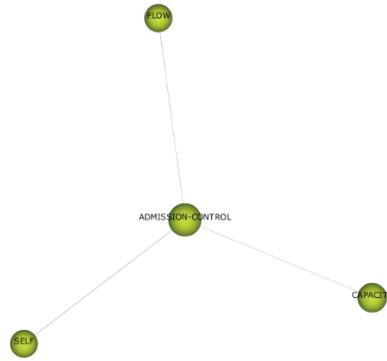
**Temas aislados y de alto desarrollo**



e. Clúster VoIP

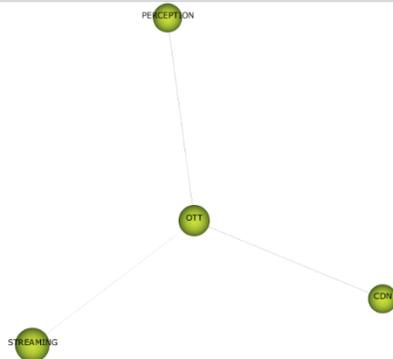


f. Clúster protocolo

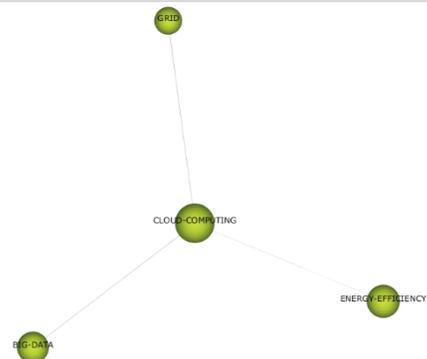


g. Clúster admisión-control

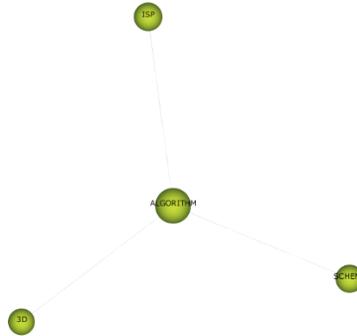
**Temas emergentes o en declive**



h. Clúster OTT.

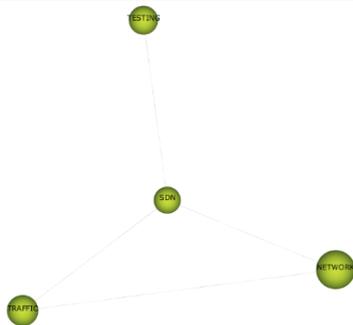


i. Clúster computación en la nube.



j. Clúster algoritmos

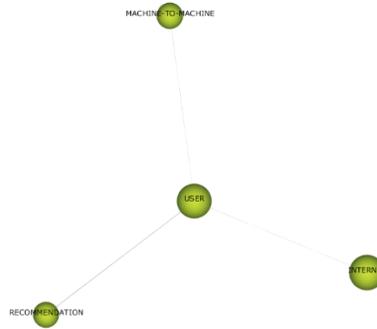
**Temas básicos y transversales**



k. Clúster SDN



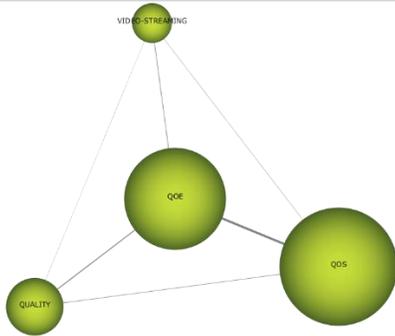
l. Clúster *framework*



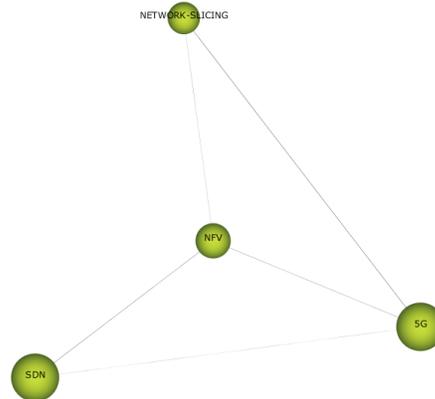
m. Clúster usuario

Figura 3.1.5. Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte III (2011 a 2015)

**Temas motores**



a. Clúster QoE



b. Clúster NFV



c. Clúster percepción

**Temas emergentes o en declive**

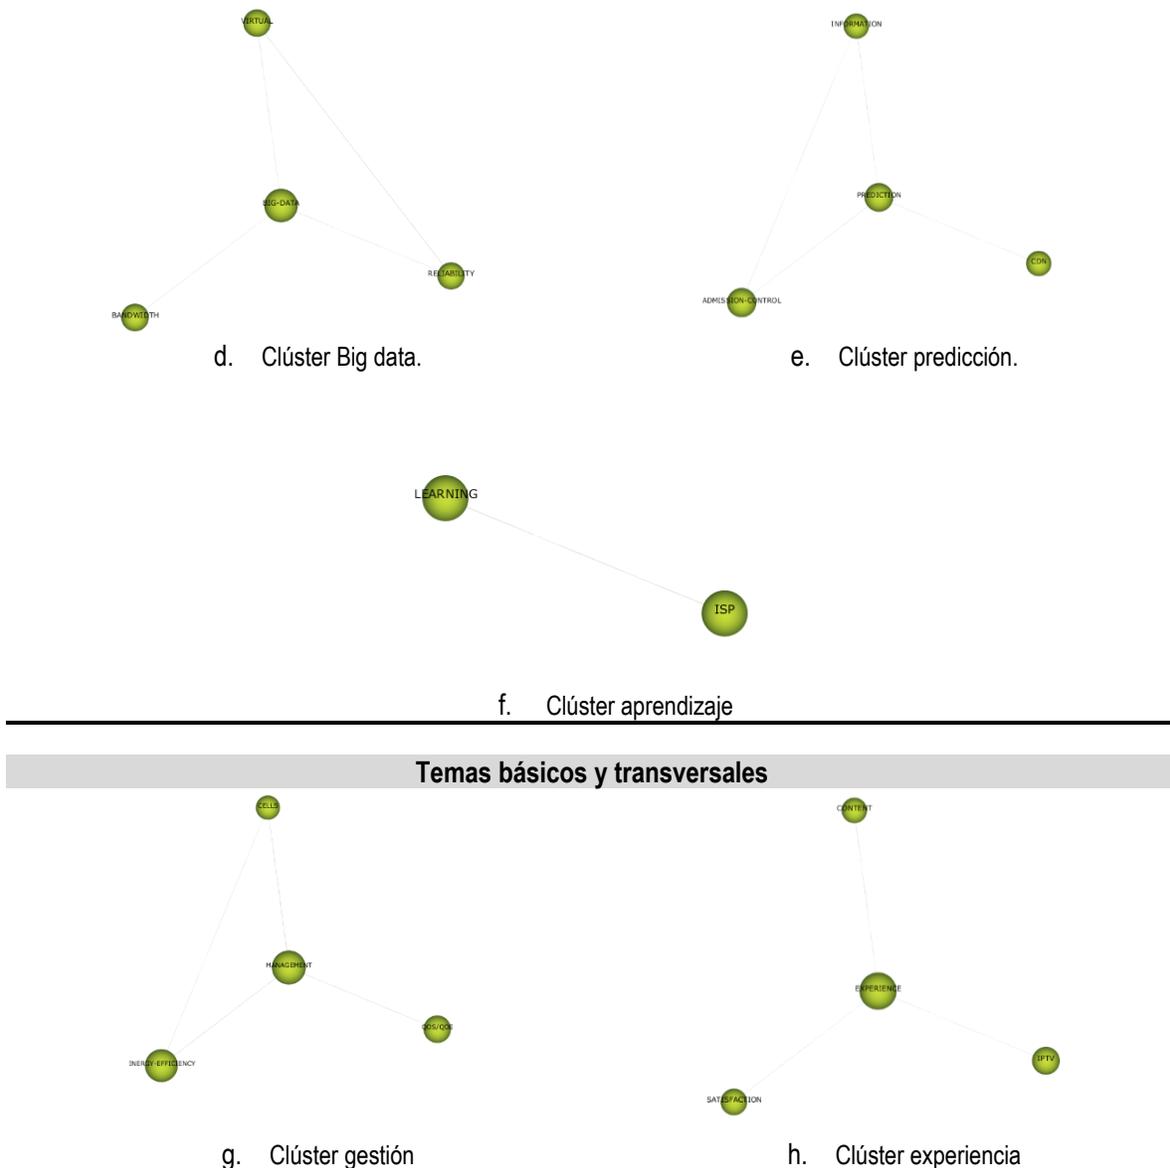


Figura 3.1.5. Relación de categorías conceptuales por cuadrante para el módulo Evolución QoE en OTT (Clúster) – Parte IV (2016 a 2020)

### 3.1.5.2. Análisis del módulo Evolución QoE en OTT por periodos de tiempo.

El análisis del módulo Evolución QoE en OTT se realiza por periodos de tiempo y de acuerdo con el mapa estratégico de los temas para las categorías conceptuales registradas. Los periodos de análisis (i.e. 4 periodos de 5 años) fueron definidos a partir de la línea de tiempo registrada en los estudios de la Red Europea de la Calidad de la Experiencia en Servicios y Sistemas Multimedia (*COST Action IC 1003*) [67], y de la línea de tiempo de los seminarios Dagstuhl en QoE [68].

El análisis por periodo presenta los resultados alineados con las preguntas formuladas para el estudio de la QoE en el aprovisionamiento de servicios OTT; esto es:

- Evolución de la ciencia en la QoE para servicios OTT: mapas estratégicos por periodo de análisis.

- Temas específicos de investigación abordados en la QoE para servicios OTT: categorías conceptuales por periodo de análisis.
- Autores más relevantes en QoE: autores más representativos por categoría conceptual y por periodo de análisis.
- Desafíos de investigación en QoE para servicios OTT: análisis por cuadrante del mapa estratégico por cada periodo de análisis.

#### A. Periodo de análisis 2000 a 2005.

##### i. Temas motores

La categoría conceptual dominante es “QoS” (ver Figura 3.1.4 parte a), la cual contiene un mayor número de documentos asociados y un índice h más elevado. Adicionalmente, la categoría QoS está altamente desarrollada y aporta significativamente al estudio de la QoE en servicios OTT (i.e. altas medidas de densidad y centralidad, respectivamente) [69] [70] [71]. El aporte al fenómeno de estudio está medido en términos del análisis de servicios que son provistos en diferentes redes (e.g. Inalámbricas, ethernet, móvil) bajo mecanismos de control de admisión para el tráfico respectivo (ver Figura 3.1.5 Parte I literal a) [72] [73] [74].

Por su parte, la categoría conceptual QoE empieza su desarrollo como tema importante (i.e. alta medida de densidad) desde un punto de vista de la satisfacción del usuario (ver Figura 3.1.5 Parte I literal b) [75], [76]

##### ii. Temas aislados y de alto desarrollo

La asignación de recursos surge como una estrategia para mejorar el desempeño y optimización de la red en la prestación de los servicios; sin embargo, no es suficientemente claro cómo afectaría la QoE en los usuarios (ver Figura 3.1.4 parte a, y Figura 3.1.5 Parte I literal c) [74] [77].

##### iii. Temas emergentes o en declive

La gestión de las redes, servicios y recursos se alinean con los términos expuestos a partir de los niveles de acuerdo de servicio (ver Figura 3.1.5 Parte I literal d) [78] [79]. Adicionalmente, se implementan estrategias de enrutamiento para el control de la congestión del tráfico de servicios (ver Figura 3.1.5 Parte I literal e) [80] [81] [82].

##### iv. Temas básicos y transversales

El desempeño de la red para el tráfico generado por sistemas de comunicación se considera un tópico común entre las categorías conceptuales (ver Figura 3.1.5 Parte I literal f) [83] [84]; sin embargo, se requiere de un mayor esfuerzo para alcanzar un desarrollo más maduro y efectivo (i.e. baja medida de densidad - Figura 3.1.4 parte a).

Finalmente, las tablas 3.1.8 y 3.1.9 presentan las categorías conceptuales y los autores más relevantes en el estudio de la QoE para servicios multimedia, respectivamente (el concepto de OTT es adoptado para el tercer periodo de análisis, 2011 a 2015).

**Tabla 3.1.8.** Categorías conceptuales más representativas para el periodo de análisis 2000 a 2004.

Categoría Conceptual	Documentos	Citaciones	Centralidad	Densidad	h-index
QoE	16	21,5	9,09	26,79	6
QoS	80	17,469	30,25	18,84	15
Desempeño	28	31,458	13,93	5,16	10

Routing	9	12,857	4,19	6,67	4
Asignación de recursos	4	31	3,86	25	3
Gestión	8	18,333	0,94	8,33	3

**Tabla 3.1.9.** Autores más representativos para el periodo de análisis 2000 a 2004.

Autores	Documentos	Citaciones	Categoría Conceptual
Siller, MA et al	1	2	QoE
Talukdar, AK et al.	1	114	QoE/QoS
Zhang, Q	1	60	QoS/Desempeño
Van Mieghem, JA	1	70	QoE/QoS/Routing
Mirhakkak, M	2	32	QoS/Asignación de recursos
De Meer, H	1	11	Asignación de recursos/Gestión
Ahn, GS	1	38	QoE
Gelenbe, E	1	75	QoS/Desempeño
Elliott, R	1	21	QoS
Wang, XD	1	20	Asignación de recursos
Fulp, EW	1	31	Gestión
Cano, MD	1	4	Gestión
Patek, SD	4	11	Routing
Ruddle, A	4	4	Routing
Sooriyabandara, M	1	20	Desempeño
Bianchi, G	2	19	Desempeño

## B. Periodo de análisis 2006 a 2010.

### i. Temas motores

La categoría conceptual dominante es “QoE” (ver Figura 3.1.4 parte b), donde se puede apreciar su crecimiento tanto en desarrollo interno como posicionamiento en el centro del estudio (i.e. altas medidas de densidad y centralidad, respectivamente), con respecto al periodo anterior [85] , [86]. En este periodo, la relación directa entre QoS y QoE empieza a evidenciar los factores de red y de aplicación que afectan la percepción de calidad del usuario, especialmente para el análisis de servicios de video (ver Figura 3.1.5 Parte II literal a) [87] [88] .

De igual manera, métricas subjetivas como el Puntaje de Opinión Media (MOS, *Mean Opinion Score*) empiezan a ser usadas con el ánimo de cuantificar la percepción de calidad en algunos servicios multimedia (e.g. VoIP, *Video Streaming* – ver Figura 3.1.4 parte a y Figura 3.1.5 Parte II literal b) [89] [90]; mientras que mecanismos de asignación justa de recursos son usados para la optimización de la red en la prestación de estos servicios (ver Figura 3.1.5 Parte II literal c) [91] [92].

### ii. Temas aislados y de alto desarrollo

Las métricas de experiencia de usuario como la satisfacción empiezan a tenerse en cuenta para medir la percepción del usuario sobre la prestación de un servicio (ver Figura 3.1.4 parte b y Figura 3.1.5 Parte II literal c) [93] [94]. De igual manera, técnicas de análisis de codificación de contenidos y de codificación de canales de

acceso para servicios multimedia son temas recurrentes en los estudios científicos (ver Figura 3.1.4 parte b y Figura 3.1.5 Parte II literal e) [95] [96].

### iii. Temas emergentes o en declive

La categoría *Conceptual frameworks* surge como un conjunto de aproximaciones para modelar el contexto de la presentación de servicios multimedia (ver Figura 3.1.4 parte b y Figura 3.1.5 Parte II literal f) [97] [98]; sin embargo, su desarrollo aún no es lo suficientemente maduro (i.e. baja medida de densidad). Por su parte, técnicas de aprendizaje automático emergen como alternativas de enrutamiento efectivo del tráfico de la red (ver Figura 3.1.4 parte b y Figura 3.1.5 Parte II literal g) [99] [100] [101].

Por otro lado, el servicio IPTV afronta desafíos desde el punto de vista del aseguramiento y percepción de la calidad al interior de su plataforma de aprovisionamiento (ver Figura 3.1.4 parte b y Figura 3.1.5 Parte II literal h) [88] [102].

### iv. Temas básicos y transversales

La gestión de las redes, servicios, y recursos realiza la transición como una categoría conceptual emergente, a una categoría necesaria y básica en la prestación de servicios para los usuarios de una red (ver Figura 3.1.4 parte b y Figura 3.1.5 Parte II literal i) [103]. En el mismo sentido, los sistemas de soporte para la estimación y predicción de recursos se toman esenciales para el aprovisionamiento de QoE en servicios multimedia (ver Figura 3.1.4 parte b y Figura 3.1.5 Parte II literal j) [104] [105]

Finalmente, las tablas 3.1.10 y 3.1.11 presentan las categorías conceptuales y los autores más relevantes en el estudio de la QoE para servicios multimedia, respectivamente (el concepto de OTT es adoptado para el siguiente periodo de análisis, 2011 a 2015)

**Tabla 3.1.10.** Categorías conceptuales más representativas para el periodo de análisis 2005 a 2010.

Categoría Conceptual	Documentos	Citaciones	Centralidad	Densidad	h-index
QoE	265	16,66	37,22	14,81	34
Fairness	39	53,394	15,36	13,36	11
Soporte	58	30,45	10,85	4,23	12
MOS	30	14,417	7,34	10,86	11
Satisfacción	8	17,667	2,58	8,33	4
Gestión	77	9	8,21	1,01	16
Codificación	10	41,737	5,8	17,78	17,78
<i>Framework</i>	45	28,057	6,64	3,67	11
Aprendizaje automático	40	26,156	6,48	4,9	13
IPTV	44	17,653	5,52	3,05	11

**Tabla 3.1.11.** Autores más representativos para el periodo de análisis 2005 a 2010.

Autores	Documentos	Citaciones	Categoría Conceptual
So-In, C	1	151	QoE/Fairness/Soporte
Kim, HL	2	77	QoE
Shaikh, J	2	70	QoE
Huang, TY	1	9	MOS

Liberal, F	2	28	MOS
Graubner, M	1	3	MOS
Li, Ying	2	47	Fairness
Zhang, Jingjing	2	10	Fairness
Phan, Khoa T.	1	117	Fairness
Ameigeiras, P	1	56	Fairness
Du, Yu	3	8	Satisfacción
You, JY	1	68	Satisfacción/Gestión
Elliott, Robert C.1	1	40	Codificación
Weng, Lihua	1	24	Codificación
Rashid, MA	1	96	Framework/Aprendizaje automático
Luo, CQ	1	84	Framework
Mitola, J	1	10	Framework
Kesselman, A	1	8	Aprendizaje Automático
Tao, Fei	1	56	Aprendizaje Automático
Kim, HL	2	77	IPTV
Gutierrez, I	2	4	Gestión
Saatsakis, A	1	4	Gestión
He, Qiang	1	8	Soporte
Tursunova, S	1	5	Soporte

### C. Periodo de análisis 2011 a 2015.

#### i. Temas motores

La categoría conceptual dominante es “QoS”, donde se refuerza el desarrollo de la categoría en términos de predicción y reconocimiento de recursos de red para servicios multimedia (i.e. altas medidas de densidad y centralidad, respectivamente – ver Figura 3.1.4 parte c) [106] [107] [108]. Nuevamente, la relación estrecha entre QoS y QoE es considerada clave en el aprovisionamiento de servicios OTT (ver Figura 3.1.5 Parte III literal a) [109] [110]).

Por su parte, la categoría de asignación de recursos incrementa su interés científico representado como la transición de un tema aislado a un tema principal de alto impacto en la QoE (i.e. cambio de cuadrante para el tercer periodo – ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal b) [111] [112]. En efecto, los esfuerzos están centrados en la optimización de los recursos de red (ver Figura 3.1.5 Parte III literal b) [113] [114]).

De igual manera, métricas como retardo o pérdida de paquetes se consideran categorías conceptuales de alto desarrollo para evaluar el desempeño que tienen algunos servicios multimedia (e.g. *Video streaming*) sobre diferentes tipos de redes (e.g. redes IP, redes inalámbricas) [115] [116], y el impacto que tienen en la percepción de calidad por parte del usuario (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literales c y d) [117] [118]).

#### ii. Temas aislados y de alto desarrollo

La masificación de redes LTE permite que servicios VoIP sean analizados en términos de su desempeño e impacto en la percepción de calidad del usuario final (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal e) [119] [120] [121]). En el mismo sentido, la categoría conceptual “protocolo” es analizada en redes móviles en

términos de asignación de recursos por protocolos específicos (e.g. OSPF) (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal f) [122].

Finalmente, mecanismos de admisión y control de los flujos empiezan sus desarrollos con el ánimo de mejorar la capacidad de transporte de la red (ver Figura parte 3.1.4 c y Figura 3.1.5 Parte III literal g) [123].

### iii. Temas emergentes o en declive

El surgimiento del concepto de Servicios Over The Top (i.e. OTT) esboza la preocupación de los operadores de red frente al crecimiento exponencial de estas plataformas (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal h) [118], y cómo estos afectan la percepción del servicio por parte del usuario [49]. De igual manera, la computación en la nube (i.e. categoría conceptual Cloud-Computing) requiere de consideraciones especiales de aprovisionamiento de calidad para funcionar apropiadamente (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal i) [124] [125].

Finalmente, diferentes algoritmos (e.g. de enrutamiento, de aprendizaje, control) son usados para gestionar recursos de acceso, de red, e intercambio de celdas para la correcta prestación de servicios OTT (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal j) [126] [111] [113].

### iv. Temas básicos y transversales

La categoría conceptual “SDN” (i.e. Redes Definidas por Software) empieza a ser considerada necesaria para abordar temas de tráfico y de aprovisionamiento de calidad en diferentes tipos de redes (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal k) [127] [128]. Asimismo, los marcos de referencia para el modelado de la QoE permiten un mejor entendimiento de los factores que afectan la percepción de calidad del usuario, pero requieren de un desarrollo mayor (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal l) [129] [130].

Finalmente, la categoría conceptual “USER” es un tema central en el desarrollo y evaluación de la QoE (ver Figura 3.1.4 parte c y Figura 3.1.5 Parte III literal m) [131] [132].

Las tablas 3.1.12 y 3.1.13 presentan las categorías conceptuales y los autores más relevantes en el estudio de la QoE para servicios OTT, respectivamente.

**Tabla 3.1.12.** Categorías conceptuales más representativas para el periodo de análisis 2011 a 2015.

Categoría Conceptual	Documentos	Citaciones	Centralidad	Densidad	h-index
QoS	729	16,969	54,43	17,66	42
User	87	24,065	9,38	2,07	12
Asignacion de recursos	175	18,316	17,38	4,25	23
Computación en la nube	80	26,449	6,93	2,65	18
Algoritmo	64	29,482	7,66	1,34	15
Retardo	53	8,626	8,18	5,88	8
Pérdida de paquetes	83	29,779	11,27	2,8	13
VoIP	91	14,941	7,38	4,35	14
Protocolo	52	32,224	5,71	4,57	12
Framework	80	46,147	9,61	2,03	19
SDN	118	18,133	8,09	1,71	17
Admisión-Control	35	56,115	4,47	3,37	12

---

OTT	51	14,1	5,97	2	11
-----	----	------	------	---	----

---

**Tabla 3.1.13.** Autores más representativos para el periodo de análisis 2011 a 2015.

Autores	Documentos	Citaciones	Categoría Conceptual
Gungor, VC	1	1154	QoS
Zheng, Zibin	4	785	QoS/User
Piro, G	2	147	QoS
Ahmed, Atiq	1	101	Asignación de recursos
Tao, Fei	1	94	Asignación de recursos/Computación en la nube/Algoritmo
El Essaili, Ali	1	48	Asignación de recursos
Zheng, Xu	1	25	Retardo
Chen, Yanjiao	1	109	Pérdida de paquetes
Mushtaq, M. Sajid	7	52	VoIP
Alfayly, A	2	23	VoIP
Dong, MX	1	71	Protocolo/Framework
Singh, SK	1	44	Protocolo/SDN
Iftikhar, M	1	7	Admisión-Control
Castellanos-Lopez, SL	2	9	Admisión-Control
Adhikari, VK	1	31	OTT
Bouten, N	2	41	OTT
Xia, YunNi	1	39	Computación en la nube
Shi, S	1	19	Algoritmo
Nam, H	3	51	SDN
Mitra, K	2	44	Framework
Jelassi, S	1	40	Framework
Ickin, S	1	8	User
De Pessemier, T	1	6	User

#### D. Periodo de análisis 2016 a 2020.

##### i. Temas motores

La categoría conceptual dominante es “QoE”, la cual presenta un alto crecimiento en el número de estudios realizados en relación con los periodos de análisis anteriores (ver Figura 3.1.4 parte d); su nivel de desarrollo (i.e. medida de densidad) denota un esfuerzo de la industria y de la academia por orientar el proceso de gestión de redes centradas en la gestión de la QoE [133] [134]. Por su parte, el nivel de aporte al fenómeno de estudio se refleja en el aumento de estudios orientados a entender la percepción de calidad para servicios multimedia, en especial, el efecto o factores que afectan la percepción de calidad en el servicio OTT de *video streaming* (i.e. medida de centralidad – ver Figura 3.1.5 Parte IV literal a) [135] [136] [137].

Adicionalmente, la relación entre QoE y QoS se refuerza mediante el estudio de situaciones que relacionan métricas de calidad de la red y de aplicación, con métricas de calidad de percepción y de evaluación del servicio consumido por parte del usuario final (ver Figura 3.1.5 Parte IV literal a) [138] [139] [140] [141].

Finalmente, la tendencia de virtualización de funciones de red sigue creciendo en interés, específicamente en dominios próximos de tecnología de telecomunicaciones de altas prestaciones y capacidades de acceso y de red (e.g. 5G) (Ver Figura 3.1.5 Parte IV literal b) [142] [143]. Asimismo, la percepción de la calidad es considerada una métrica importante dentro del espacio integral de la QoE (ver Figura 3.1.4 parte d y Figura 3.1.5 Parte IV literal c) [144].

**ii. Temas aislados y de alto desarrollo**

Diferentes métricas son analizadas con el ánimo de cuantificar la percepción de calidad en diferentes servicios multimedia; esto es, métricas como PSNR, MOS, utilidad, equidad, SSIM son definidas para proporcionar esquemas de entendimiento del nivel de calidad entregado al usuario final o de optimización de recursos para la prestación de servicios multimedia (Ver Figura 3.1.4 parte d) [145] [146] [147] [148].

**iii. Temas emergentes o en declive**

Temas emergentes como la categoría “Big Data” surgen como alternativas para el desarrollo de mecanismos capaces de entender y comprender grandes cantidades de datos producidos en el contexto del aprovisionamiento de servicios OTT (ver Figura 3.1.4 parte d y Figura 3.1.5 Parte IV literal d) [149]. De igual manera, las diferentes técnicas de aprendizaje automático son usadas para el desarrollo de sistemas de predicción de comportamiento de tráfico, y gestión de la QoE y QoS (ver Figura 3.1.4 parte d y Figura 3.1.5 Parte IV literal e) [150].

Finalmente, estrategias de colaboración entre los operadores y proveedores de servicios OTT centran su esfuerzo en una integración técnica orientada a mantener una relación justa en la QoE del usuario final (ver Figura 3.1.4 parte d y Figura 3.1.5 Parte IV literal f) [151] [152].

**iv. Temas básicos y transversales**

La categoría conceptual “Gestión” se considera un tema clave en la prestación apropiada de servicio OTT con base en la relación existente entre la QoS y QoE (ver Figura 3.1.4 parte d y Figura 3.1.5 Parte IV literal g) [153] [154]. En el mismo sentido, los marcos de referencia para analizar la QoE son centrales para comprender los aspectos que afecta la percepción de calidad del usuario y cómo estos factores están relacionados [155][155]

Finalmente, la experiencia del usuario pasa la frontera de tema emergente a un campo necesario para el entendimiento de la QoE en términos de sus factores impacto (e.g. contenido), medición (e.g. aspectos de aplicación del servicio), y estimación (e.g. métrica de satisfacción) (ver Figura 3.1.4 parte d y Figura 3.1.5 Parte IV literal h) [156] [157]; sin embargo, aún requiere de un mayor análisis y desarrollo (i.e. medida de densidad baja).

Las tablas 3.1.14 y 3.1.15 presentan las categorías conceptuales y los autores más relevantes en el estudio de la QoE para servicios OTT, respectivamente.

**Tabla 3.1.14.** Categorías conceptuales más representativas para el periodo de análisis 2016 a 2020.

Categoría Conceptual	Documentos	Citaciones	Centralidad	Densidad	h-index
QoE	667	6,742	50,76	20,88	29
Utilidad	21	34,278	4,85	30,71	3
Gestión	28	11,731	3,12	0,89	7

NFV	129	32,238	11,57	5,23	12
Percepción	154	11,155	15,12	1,97	15
PSNR	9	3,167	0,69	14,06	2
MOS	38	2,046	5,75	3,9	4
Fairness	43	9,397	8,59	8,9	7
Big data	68	3,994	4,29	1,42	8
Learning	28	11,731	3,12	0,89	7
Predicción	66	12,925	7,74	1,73	11
<i>Framework</i>	198	6,223	20,5	3,05	18
Experiencia	77	7,924	9,17	1,05	8

**Tabla 3.1.15.** Autores más representativos para el periodo de análisis 2016 a 2020.

Autores	Documentos	Citaciones	Categoría Conceptual
Zheng, Xu	1	55	QoE
Xu, LN	1	48	QoE
Amjad, M	1	41	QoE
Agiwal, M	1	602	NFV/Utilidad/Gestión
Martin, Angel	2	7	NFV
Yang, Mao	2	8	NFV
Shin, DH	1	41	Percepción
Wang, Hongbing	1	14	Percepción
Akhtar, Z	2	8	PSNR
Pal, D	4	7	MOS
Nourikhah, H	1	10	MOS
Gueguen, C	2	3	Fairness
Zhou, Weihao	1	1	Big data
Niephaus, C	2	24	Big data
Floris, A	4	20	Learning
Ahmad, Arslan	5	20	Learning
Boutaba, R	2	41	Predicción
Sahin, O	1	1	Gestion
Laghari, AA	8	36	<i>Framework</i>
Nourikhah, H	1	10	Experiencia
Condori-Fernandez, N	1	1	Experiencia

**NOTA:** Para mayor información de la estructura y contenido del clúster de cada categoría conceptual por cada periodo de tiempo, referirse al Anexo E.

La Tabla 3.1.16 relaciona la salida de la etapa SM-5 con los productos generales de la etapa y particulares del módulo Evolución QoE en OTT del modelo.

**Tabla 3.1.16.** Productos de la etapa SM-5 y del módulo Evolución QoE en OTT.

Salidas SM-5	Producto general de la etapa	Producto particular del módulo
--------------	------------------------------	--------------------------------

Visualización del mapa de la literatura. Mapa de la literatura por categoría o por temas conceptuales. Diagrama estratégico Figura 3.1.4

### 3.1.6. Síntesis del módulo Evolución QoE en OTT

El módulo Evolución QoE en OTT presenta, en detalle, la evolución conceptual, tecnológica y científica en el aprovisionamiento de la QoE en el contexto de una Telco. En efecto, el análisis del diagrama estratégico por cuadrante en cada uno de los periodos definidos, establece la base conceptual sobre la cual se desarrolla el modelo de correlación. Así, se tiene:

- El concepto de la QoE ha evolucionado desde una concepción meramente técnica, determinada por elementos exclusivos de la red de una Telco (i.e. QoE centrada en la red), hasta una concepción más holística, determinada por el comportamiento del usuario (i.e. QoE centrada en el usuario). En esta última aproximación, el comportamiento del usuario es determinante en la QoE que este tiene luego de consumir servicios OTT. En particular, aspectos característicos de la experiencia de usuario como las emociones o necesidades sobre el uso de alguna aplicación, sistema o servicio, impactan en la percepción de la calidad de los servicios provistos por una Telco. En consecuencia, el análisis de la QoE implica la integración de los elementos determinantes en un contexto técnico de red con los elementos característicos en el contexto de usuario.
- Uno de los principales temas abordados por la comunidad científica se centra en modelar la QoE en el aprovisionamiento de servicios OTT. Para ello, diferentes marcos de referencia se proyectan como propuestas novedosas para el entendimiento integral de la QoE en el contexto de una Telco. De igual manera, el impacto de la QoS sobre la QoE, la asignación de recursos de red de acuerdo con el nivel de QoE, los modelos de estimación de la QoE, la gestión de la QoE en entornos virtuales, y las plataformas de aprovisionamiento de QoE en redes definidas por software, son algunos de los temas identificados en el módulo QoE para servicios OTT que son objeto de estudio por parte de la comunidad científica y empresas de telecomunicaciones.
- En cada uno de los temas de interés que fueron hallados, existen diferentes desafíos que requieren ser resueltos para mejorar la comprensión y operación de la QoE en la infraestructura de red de una Telco; por ejemplo, medir de manera objetiva la QoE para potenciar los sistemas de gestión de red, modelar los factores de influencia de la QoE para definir con mayor claridad los marcos de referencia, definir las variables técnicas de operación de los puntos de interconexión entre los elementos de red que intervienen en la cadena de aprovisionamiento de los servicios OTT, definir métricas centradas en el usuario final para el establecimiento de políticas de QoE en la oferta de servicios.

Por otro lado, diferentes autores como Boutaba R., Sahin O., Nourikhah H., y Zheng Xu se destacan por los resultados alcanzados en la comprensión de la QoE en el contexto de un Telco (ver Tabla 3.1.15)

Finalmente, los siguientes aspectos aparecen como relevantes en la comprensión del aprovisionamiento de la QoE en el consumo de servicios OTT a partir de unas condiciones específicas de QoS:

- Técnicas de monitorización de la red.
- Técnicas de caracterización, clasificación y tratamiento de tráfico.
- Clases de servicio definidas a partir de los requerimientos de QoS.
- Descriptor técnico de red que permite diferenciar servicios de acuerdo con la QoS suministrada por la Telco
- Factores de influencia en la QoE de los usuarios.

- Sistemas de gestión de la QoE.

Los anteriores aspectos permiten trazar varias metas de negocio por parte de una Telco. En particular, la necesidad de monitorizar la QoE en el aprovisionamiento de servicios OTT al interior de su infraestructura de red.

### 3.2. MÓDULO ELEMENTOS CONCEPTUALES

El módulo Elementos conceptuales da inicio con la ejecución de la etapa SLR-1, la cual recibe el resultado del mapa estratégico en el aprovisionamiento de la QoE para servicios OTT bajo condiciones de QoS obtenido en la primera iteración (i.e. salida SM-5 mapa estratégico QoS/QoE/OTT en Figura 2.2.1). En consecuencia, este módulo describe las características de los elementos conceptuales del modelo a través de la realización de las etapas de la iteración SLR (ver Figura 2.2.1).

#### 3.2.1. Definición de las preguntas de revisión (SLR-1)

Las preguntas de revisión están orientadas al descubrimiento y definición de los elementos conceptuales del modelo de QoE para servicios OTT. Para ello, el resultado del análisis del módulo Evolución QoE en OTT se toma como principal referente en la construcción conceptual del modelo (i.e. identificación y designación de conceptos), esto es: las categorías conceptuales “QoE”, “QoS” y “OTT” se toman como base conceptual sobre la cual el modelo es construido (i.e. módulos conceptuales). Las categorías conceptuales restantes serán tomadas como descriptores que dotan de contexto a cada módulo conceptual (e.g. “desempeño”, “gestión”, “aprendizaje automático”, “usuario”, “experiencia”, “percepción”). Finalmente, la relación entre los módulos conceptuales a través de la conexión de sus descriptores de contexto permitirá la identificación y designación de los elementos conceptuales del modelo.

Teniendo en cuenta lo anterior, las preguntas de revisión son:

- ¿Cuáles son los elementos conceptuales del modelo de QoE para Servicios OTT?
- ¿Qué características esenciales posee cada elemento conceptual del modelo?
- ¿Qué modelos o técnicas de aprendizaje automático son empleadas en el estudio de las características de los elementos conceptuales del modelo?
- ¿Qué métricas de evaluación son consideradas para cada uno de los elementos conceptuales?

La Tabla 3.2.1 relaciona la salida de la etapa SLR-1 con los productos generales de la etapa y particulares del módulo Elementos conceptuales.

**Tabla 3.2.1.** Productos de la etapa SLR-1 y del módulo Elementos conceptuales.

Salidas SLR-1	Producto general de la etapa	Producto particular del módulo
Descripción de la necesidad	Contexto del fenómeno	Descripción del dominio (Protocolo Anexo B)
Estructuración de las preguntas	Preguntas de revisión.	Preguntas

#### 3.2.2. Identificación de la búsqueda (SLR-2A)

La búsqueda en esta segunda iteración se restringe a la obtención de información técnica especializada relevante para la definición de los elementos conceptuales. En este sentido, la búsqueda de los documentos se ha realizado en las bases de datos de organismos de estandarización, control y regulación internacionales y nacionales.

La Tabla 3.2.2 presenta los resultados obtenidos luego de ejecutar las siguientes cadenas de búsqueda de manera separada:

- (Quality of Experience OR QoE)
- (Quality of Service OR QoS)
- Perceived Quality.
- OTT OR Provisioning (“OTT provisioning”)
- Machine learning

**Tabla 3.2.2.** Cantidad de especificaciones técnicas por organismos de estandarización y control.

ITU-T	IETF (RFC)	3GPP	ETSI
16	26	12	10
<b>Total</b>			
64			

La Tabla 3.2.3 relaciona la salida de la etapa SLR-2A con los productos generales de la etapa y particulares del módulo Elementos conceptuales.

**Tabla 3.2.3.** Productos de la etapa SLR-2A y del módulo Elementos conceptuales.

Salidas SLR-2A	Producto general de la etapa	Producto particular del módulo
Identificación de los principales estudios relacionados con la temática	Cadenas de búsqueda	Cadenas de búsqueda separadas, e.g., <ul style="list-style-type: none"> <li>• Quality of Experience OR QoE</li> <li>• OTT OR Provisioning (“OTT provisioning”)</li> </ul>
	Conjunto de artículos obtenidos de diferentes bases de datos de organismos de estandarización	Tabla 3.2.2

### 3.2.3. Selección de los estudios primarios (SLR-2B)

La selección de documentos permite filtrar los estudios en relación con el aporte al entendimiento de las características de los elementos conceptuales del modelo. Para ello, criterios de inclusión y de exclusión han sido definidos; esto es:

#### 3.2.3.1. Criterios de inclusión.

- Normatividad internacional y nacional en relación con la gestión de la QoE, aprovisionamiento de QoS en redes 4G/5G, y despliegue de servicios OTT en una Telco.
- Disertaciones de expertos en temas de QoE, QoS, y OTT desarrolladas en foros, memorias de seminarios, y artículos de reflexión.

#### 3.2.3.2. Criterios de exclusión.

- Normatividad en estudio o no vigente

La Tabla 3.2.4 relaciona la salida de la etapa SLR-2B con los productos generales de la etapa y particulares del módulo elementos conceptuales.

**Tabla 3.2.4.** Productos de la etapa SLR-2B y del módulo Elementos conceptuales.

Salidas SLR-2B	Producto general de la etapa	Producto particular del módulo
----------------	------------------------------	--------------------------------

Evaluación de la relevancia de los artículos – Momento uno (1)	Criterios de selección refinados con criterios de calidad	Criterios para el tipo de informe técnico especializado.
--	---	--

### 3.2.4. Evaluación de la calidad de los estudios (SLR-2B)

Esta etapa tiene dos momentos. El primero, enfocado en delimitar el espacio y cantidad de documentos técnicos especializados, es decir, definir los organismos de estandarización, control y regulación donde se realiza la búsqueda, y obtener aquellos documentos con mayor grado de pertinencia (i.e. año de vigencia); este momento está articulado en conjunto con la etapa de selección de estudios primarios. El segundo momento, centrado en el procedimiento de selección de estudios en relación con la calidad de su contenido y clasificados según la relación entre los módulos conceptuales identificados (i.e. QoE, QoS, OTT - ver Anexo B).

La Tabla 3.2.5 presenta el resumen de los documentos asociados en cada relación de los módulos conceptuales de acuerdo con su nivel de pertinencia y relevancia. Es importante resaltar que un estudio puede pertenecer a varias categorías; sin embargo, este ha sido clasificado en aquella categoría donde su aporte es más significativo.

**Tabla 3.2.5.** Estudios clasificados por categoría y relación conceptual para el periodo 2016-2020 - Resumen.

Clasificación de estudios	
Categoría o módulo conceptual	Documentos
QoE	59 (e.g. [158] [159] [160] [161])
QoS	4 (e.g. [162] )
OTT	6 (e.g. [163] [34])
Relación conceptual o elementos conceptuales del modelo	Documentos
QoE-QoS	64 (e.g. [137] [164] [138])
QoS-OTT	7 (e.g. [153] [150] )
QoE-OTT	78 (e.g. [165] [166] [167] [168])

Para realizar la evaluación de la calidad de los estudios y determinar aquellos que son objeto de análisis detallado, ha sido definido un índice de análisis absoluto (Índice de Análisis Absoluto - IAA). Para ello, los criterios de relevancia y pertinencia se toman como base para el establecimiento del índice final. La relevancia hace referencia al nivel de impacto del estudio medido en el número de citas; la pertinencia, un criterio subjetivo medido en escala de 1 a 5 de acuerdo con el aporte a la categoría o relación conceptual.

Los criterios de relevancia y pertinencia son definidos de acuerdo con una escala absoluta y ponderada; esto es:

- El número de citas de cada artículo, clasificado por categoría conceptual (ver Tabla 3.2.5), es trasladado a una escala absoluta medida de 1 a 5 (i.e. Nivel relevancia: 1-Pobre, 2-Baja, 3-Media, 4-Alta, y 5-Total). Este puntaje en la escala absoluta se denomina "Score\_Relevancia".
- El criterio de pertinencia es un valor en la escala absoluta que es dado a partir del nivel de aporte del estudio a la categoría conceptual donde este se encuentra clasificado (i.e. Nivel pertinencia: 1-Pobre, 2-Baja, 3-Media, 4-Alta, y 5-Total). Este puntaje en la escala absoluta se denomina "Score\_Pertinencia", y es una medida subjetiva de quién analiza el estudio a partir de los metadatos obtenidos en la etapa SM-5 (e.g. palabras clave, resumen).
- Los puntajes respectivos son ponderados, dando un mayor peso al puntaje de pertinencia. En este caso, los pesos son 0.6 para "Score\_Pertinencia" y 0.4 "Score\_Relevancia". Lo anterior se determina sobre el hecho de responder en mayor medida a las preguntas que orientan la definición del modelo (ver Anexo B sección 6 - evaluación de calidad).

Es importante resaltar que la transformación del número de citas a una escala absoluta ha sido abordada desde el concepto de clustering; es decir, se han usado algoritmos de agrupamiento con el ánimo de situar los grupos generados en un nivel de relevancia específico. En ese sentido, los algoritmos CobWeb [169] y Maximización de Expectativas (EM) fueron ejecutados en el entorno de Weka [170]. Para ambos algoritmos se usó la configuración por defecto en cada uno de sus parámetros. Sin embargo, en los casos donde los resultados no son válidos, es decir, donde el número de clúster generados por cada algoritmo superan la cantidad de rangos definidos de relevancia (i.e. 5 niveles) o donde solo se genera un clúster para agrupar artículos con gran diferencia entre sus números de citas (e.g. artículos con 0 citas y artículos con 602 citas en un solo clúster), el algoritmo no es aplicado para la determinación de los rangos en dicha categoría conceptual (e.g. el algoritmo EM no es aplicado en la categoría QoS por agrupar todos los artículos en un solo clúster).

La Tabla 3.2.6 resume los rangos de citas para cada nivel de relevancia de acuerdo con el resultado de ejecutar los algoritmos de clustering respectivos.

**Tabla 3.2.6.** Rangos de relevancia por categoría y relación conceptual

Categoría Conceptual	Algoritmo de agrupamiento	Rangos de Relevancia por número de citas (i.e. clúster)
QoE	EM	<ul style="list-style-type: none"> <li>Pobre [0, 0]</li> <li>Baja [1, 2]</li> <li>Media [3, 5]</li> <li>Alta [6, 7]</li> <li>Total [17, 21]</li> </ul>
		<ul style="list-style-type: none"> <li>Pobre [0, 1]</li> <li>Baja (No considerada)</li> <li>Media (No considerada)</li> <li>Alta (No considerada)</li> <li>Total [602, 602]</li> </ul>
QoS	cobWeb	<ul style="list-style-type: none"> <li>Pobre [0, 0]</li> </ul>
OTT	EM	
<b>Relación conceptual</b>		
QoE-QoS	CobWeb	<ul style="list-style-type: none"> <li>Pobre [0, 3]</li> <li>Baja [4, 6]</li> <li>Media [10, 12]</li> <li>Alta [18, 18]</li> <li>Total [41, 41]</li> </ul>
		<ul style="list-style-type: none"> <li>Pobre [0, 1]</li> <li>Baja (No considerada)</li> <li>Media [8, 13]</li> <li>Alta (No considerada)</li> <li>Total [41, 41]</li> </ul>
QoS-OTT	CobWeb	<ul style="list-style-type: none"> <li>Pobre [0, 2]</li> <li>Baja [3, 4]</li> <li>Media [5, 7]</li> <li>Alta [12, 17]</li> <li>Total [36, 36]</li> </ul>

Finalmente, los estudios para el análisis son etiquetados de acuerdo con el IAA; las etiquetas son: seleccionado, candidato, y en reserva. Los estudios con etiqueta “seleccionado” son objeto de análisis detallado para la obtención de las características de los elementos conceptuales. Los estudios con etiqueta “candidato”, serán usados como complemento para el análisis en caso de ser necesario. Los estudios con etiqueta “reserva” son

considerados como fuente de apoyo para realimentar el desarrollo del módulo Modelo correlacional QoS-QoE del modelo cuando así se requiera.

La Tabla 3.2.7 presenta el etiquetado de los estudios de acuerdo con el IAA.

**Tabla 3.2.7.** Etiquetado de estudios con base en el IAA.

Rango IAA	Condición de evaluación	Etiqueta
[3, 5]	NA	Seleccionado
	Score_Relevancia: 1 Score_Pertinencia: 4	Seleccionado
[2, 3]	Score_Relevancia: 2 Score_Pertinencia: 3	Seleccionado
	Score_Relevancia: 1 Score_Pertinencia: 3	Candidato
	Otra condición	Reserva
[1, 2]	NA	Reserva

La Tabla 3.2.8 relaciona la salida de la etapa SLR-2B con los productos generales de la etapa y particulares del módulo Elementos conceptuales.

**Tabla 3.2.8.** Productos de la etapa SLR-2B y del módulo Elementos conceptuales.

Salidas SLR-2B	Producto general de la etapa	Producto particular del módulo
Clasificación de artículos – Momento dos (2)	Artículos ponderados con base en criterios de calidad.	Tabla rango IAA y Tabla de etiquetado

### 3.2.5. Extracción y monitorización de los datos de los estudios seleccionados (SLR-2C)

La extracción y monitorización de los datos permite la captura de características representativas de los elementos conceptuales del modelo; esto es:

- Parámetro de medición de calidad: característica que representa el elemento de calidad medido en cada nivel de influencia de la QoE. El nivel de influencia o factor de influencia de la QoE ha sido definido por F. Guyard et al. en [171] y luego adoptado por la ETSI TS 103 294 [172].
- Modelo propuesto: característica que representa el modelo de aprendizaje automático o algoritmo de correlación usado para obtener un valor de calidad percibida por el usuario final.
- Servicio o aplicación: característica que representa el servicio o la aplicación usada como elemento de análisis del modelo propuesto.
- Dominio de aplicación: característica que representa el tipo de red usada como escenario de experimentación, y modalidad del escenario de prueba (e.g. real, simulado, *test bed*).
- Conjunto de datos: característica que representa el conjunto de datos obtenidos o generados para modelar su comportamiento (e.g. detallado, disponible).
- Meta: característica que representa la finalidad del estudio; es decir, el uso práctico de la propuesta.
- Métrica de evaluación de calidad: característica que representa la medida de calidad usada para cuantificar la percepción o evaluación de la calidad percibida o de la experiencia por parte del usuario final.

Estas características están definidas con el ánimo de entender la QoE en el aprovisionamiento de servicios OTT bajo condiciones de QoS, e identificar y designar los elementos conceptuales del modelo. En ese sentido, las tablas 3.2.9 Parte I, y 3.2.10 Parte II presentan la matriz de los datos obtenidos de algunos estudios seleccionados en el periodo de análisis 2016 -2010.

Tabla 3.2.9. Matriz de características esenciales del modelo QoE para servicios OTT – Parte I

Modelos	Servicio/App	DominioApp [Tipo de red Conjunto de datos		Meta	Métrica de evaluación de calidad	Identificador del Estudio
Hipótesis Exponencial (QoE)	Video Streaming - VoIP	5G: C-RAN (Cloud-based Radio Access Network). Simulada	No disponible. Simulados inyectando tráfico	Analizar la percepción de la calidad a través del cambio de parámetros de QoS	MOS: Calculada con la hipótesis exponencial. No feedback	1. [157]
Regresión lineal (MOS)	e-Salud, juegos, download	SDN: Simulada Mininet, OVS	No disponible. Basae de conocimiento - KB (Prioridad del flujo, dirección física del servicio, información del usuario, políticas de QoS, feedback del usuario ) Crowdsourced QoE tests. Score de calidad: 7 Niveles (Muy satisfecho, satisfecho, algo satisfecho, ni satisfecho ni no satisfecho, algo desatisfecho, desatisfecho, y muy desatisfecho)	Asignación de recursos: Cambio del camino de enrutamiento	MOS: Calculada con ecuación. Feedback usuario (Score y dirección web)	2. [158]
Multidimensional IQX model: Active Learnig	Video	Fija. Reproducción de videos a tasa diferentes.		Modelar QoS-QoE	VQA: Evaluación de Caliad de Video	3. [159]
Análisis de series de tiempo o algoritmos de ML legados	Video Streaming, Web Browsing, banda ancha móvil (FTP)	Móvil: LTE [Field Trial]. Online y Offline fases	Fuente de datos: Terminal, Radio/Core Network, OSS, BSS	Revisión de las deficiencias y retos de las aplicaciones de TMA (Traffic Monitoring and Analisis) para redes móviles y cómo estas pueden ser empoderadas con BDA (Big Data Analytics)	NA	4. [160]
Ecuación QoE	Video	Fija. Simulada	No disponible. No documentado	Analizar la percepción de la calidad a través del cambio de parámetros de QoS	MOS: Trasladaada a partir del valor QoE obtenido. Métdo: DSCQS, SSCQE. Escala [Usuarios: muy satisfechos, satisfechos, algunos desatisfechos, muchos desatisfechos, casi todos	5. [136]
Proceso de decisión de Markov - Aprendizaje reforzado	Video Streaming	SDN. Simulada, OVS	Switches: Link-Layer Discovery Protocol (LLDP)	Maximizar QoE mientras se mantienen las restricciones de QoS	QoE Calculada con Weber-Fechner law (WFL), IQX	6. [163]
Modelo conceptual	No especifica	5G. Teórico	No disponible. No documentado	Mapear métricas QoS a QoE	* - Pruebas de QoS percibida por el usuario (e.g. MOS), Encuestas subjetivas QoE (e.g. Cuestionarios), Modelado de calidad de medios (e.g. evaluación perceptiva de la calidad de la voz). - Operadores: Satisfacción del cliente (CSAT), Puntaje de esfuerzo del cliente (CES), MOS escala 5 niveles [1-Pobre, 2-Mala, 3-Justa, 4-Buena 5-Exceletrne], Prregunta "Tu evaluación total de la	7. [137]
Aplicación basada en ML (K-Means)	Video	Fija. Experimento controlado	No documentado. Repositorio de videos de prueba	Medir la fiabilidad de los ratings subjetivos de calidad técnica para vidos que presentan fallas		8. [167]
Técnicas de aprendizaje automático para análisis de las métricas QoS	Video	Móvil.	Documentado. Tomado de herramienta: SpeedVideo Global Operating Platform (SVGOP).	Analizar la QoE de video a partir de la definición de un framework conducido por datos	vMOS (Modelo de Huawei)	9. [164]
Clasificador basado en ML (K-means)	Video (MPEG-DASH, HEVC)	Fija. Experimento controlado - Testbed	No disponible. Métricas QoS - QoE (Tomadas como QoS de aplicación)	Integrar técnicas de ML en controladores SDN para pronosticar demanda de recursos y actuar de manera apropiada.	No especificada	10. [166]
Propuesta conceptual	Video	OTT - Telco. Emulado [IMUNES]. Degradación en la re	Disponible. Documentado - YouTube	Definir dats a compartir por el OTT para mejorar los modelos de estimacion QoE en red basados en ML	MOS clase: [MOS > 4, Alta]; [3<=MOS<4, Media]; [MOS<3, baja]	11. [165]

**Tabla 3.2.10.** Matriz de características esenciales del modelo QoE para servicios OTT – Parte II

Parámetro de medición de calidad						
IF Ulrich Reiter et al (2014) - Factors Influencing Quality of Experience.						
Humano		Contexto			Sistema	
ARCU L.Skorin-kavop & M. Varela (2012) -A Multi-Dimensional View of QoE : the ARCU Model						
Usuario	Contexto			Aplicación	Recursos	
Layered ETSI TS 103 294 (2012)						
Identificador	Usuario	Humano	Contexto	Interfaz	Aplicación	Recursos
Estudio	Usuario	Humano	Contexto	Interfaz	Aplicación	Recursos
1						QoS: Tasa pérdida de paquetes, retardo
2						QoS: Tasa de bits, Latencia, Tasa pérdida de paquetes.
3					QoS: Bit y Frame Rate, resolución, complejidad temporal, complejidad espacial de segmentos de video	[Razón de stalling, retardo], Web Browsing [razón éxito de despliegue, retardo de respuesta], Banda ancha móvil [Velocidad de descarga]
4						Pérdida de paquetes, Nivel de ráfaga, Jitter, Retardo, Ancho de banda
5						paquetes, Jitter, Ancho de banda
6						de volumen de tráfico, Rendimiento experimentado por el usuario final, latencia, disponibilidad, Retención, Eficiencia energética, seguridad.
7						
8					QoS: Resolución espacial (píxeles), tasa de frame	
					QoS: Calidad de video [Tasa promedio de play, Tasa de descarga total, Btrrate]; Carga Inicial [Tasa máxima inicial, RTT, Latencia de buffering inicial, Descarga de buffer inicial]; [Tiempo de play, Duración del play, tiempos de stalling, Razón de stalling]	QoS: Latencia y ancho de banda
9					QoS: Retardo inicial, tiempo de stalling, número de switches de calidad, tiempos de inter switching	
10				Métricas del reproductor		
					Compartir por el OTT: Contenido [Categoría de video, promedio de bitrate en todos los niveles, número de vistas], Playback [Información stalling, niveles de calidad del play, retardo inicial]	Compartir por el OTT: Sistema [Retardo fin a fin]
11	Compartido por el OTT: Usuario [configuración del reproductor, interacción]			Compartido por el OTT: Sistema [Dispositivo final]		

La Tabla 3.2.11 relaciona la salida de la etapa SLR-2C con los productos generales de la etapa y particulares del módulo Elementos conceptuales.

**Tabla 3.2.11.** Productos de la etapa SLR-2C y del módulo Elementos conceptuales.

Salidas SLR-2C	Producto general de la etapa	Producto particular del módulo
Identificación de los datos de los estudios primarios.	Matriz de datos	Tablas 3.2.9 y 3.2.10

### 3.2.6. Síntesis de los datos (SLR-2D)

La síntesis descriptiva de los estudios etiquetados como “seleccionados” parte del análisis de las características representativas definidas previamente (ver sección 3.2.5); esto es:

#### 3.2.6.1. Modelo propuesto

De manera general, los estudios encuentran en las técnicas de aprendizaje automático una aproximación objetiva y apropiada para desarrollar modelos basados en datos que representen el comportamiento del uso de recursos de red en el aprovisionamiento del servicio sobre una red de telecomunicaciones. Estos modelos tienen una finalidad común, analizar la percepción de la calidad que un usuario tiene sobre las condiciones de calidad provistas por su red de conexión; sin embargo, los modelos son entrenados con datos ajustados y limitados a servicios particulares, y en su mayoría, desarrollados bajo condiciones controladas en experimentos diseñados. En consecuencia, estos modelos responden a necesidades particulares de escenarios específicos, y que difícilmente son acoplados a entornos reales con particularidades diferentes con las que fueron modelados.

Por otra parte, algunos estudios centran sus propuestas en modelos matemáticos bien conocidos y científicamente aceptados para validar la incidencia de nuevos parámetros de QoS en la percepción de calidad del usuario final o de evaluar el desempeño de un servicio sobre condiciones de red diferentes (e.g. variación del retardo, pérdida de paquetes). Es de resaltar que los estudios realizan adaptaciones de los modelos científicos para evaluar las condiciones adicionales en la prestación de un servicio.

#### 3.2.6.2. Servicio o aplicación

La mayoría de estudios centran su análisis sobre servicios de *video streaming* y VoIP, principalmente por la densidad de tráfico que genera este tipo de servicios. El crecimiento de usuarios de Internet es cada vez mayor, lo cual genera una mayor demanda de recursos de red para soportar las elevadas tasas de tráfico que requieren los servicios OTT, en particular, aquellos que ofrecen contenido en alta definición (e.g. HD, UHD, 4K). Un reporte reciente de Cisco [173] ilustra el crecimiento de usuarios en los últimos años, y proyecta la penetración de Internet para el año 2023. En consecuencia, un mayor consumo de servicios exige que las redes adapten sus recursos para mantener una calidad de aprovisionamiento que no afecte de manera considerable la percepción de calidad del usuario, en particular, para redes móviles donde el servicio de video tiene un mayor consumo.

#### 3.2.6.3. Dominio de aplicación

Los estudios enfocan sus esfuerzos en proponer enfoques que mejoren la prestación de recursos en red donde estos son limitados y se requiere un uso eficiente; es decir, las redes móviles son objeto de análisis principalmente en su red de acceso. Adicionalmente, propuestas con enfoques de virtualización (e.g. SDN) de recursos tiene un alto interés en la nueva generación de comunicaciones (i.e. 5G). Sin embargo, la mayoría de trabajos validan sus propuestas en entornos simulados bajo condiciones de red controladas, haciendo compleja la extrapolación de los resultados obtenidos a entornos reales de tráfico.

#### 3.2.6.4. Conjunto de datos

Los conjuntos de datos que relacionan las métricas de QoS y de percepción de calidad, son obtenidos a través de la instrumentalización de los dispositivos de red que actúan en la prestación del servicio; esto es, aplicaciones instaladas en los dispositivos móviles que recolectan información de la aplicación objeto de estudio y características del dispositivo, sondas que recolectan información de los dispositivos de red (e.g. enrutadores, eNodeB), simuladores de tráfico que generan condiciones de calidad de la red, y servidores de prestación de servicio (e.g. servidores de *video streaming*).

Aunque estos datos estén disponibles en muy pocos estudios, estén débilmente documentados y que representen datos particulares del escenario de prueba controlado, la estrategia de recolección es aplicable de manera transversal a propuestas más generalizadas.

### 3.2.6.5. Meta

La finalidad de los estudios es variada; sin embargo, se puede generalizar que el objetivo se centra en modelar la relación entre QoE y QoS bajo ciertas características específicas, y entender el aprovisionamiento de la QoE para la construcción de modelos de gestión de red y de aplicación.

### 3.2.6.6. Métrica de evaluación de calidad

La mayoría de los estudios evalúan la percepción de calidad que un usuario tiene sobre condiciones de calidad de la red al momento de consumir un servicio en particular. Las evaluaciones de calidad se pueden ver de dos maneras, objetiva y subjetiva. La primera, toma modelos que obtienen un valor estimado de QoE a partir de unos parámetros de calidad definidos; la segunda, toma evaluaciones del usuario final que permiten clasificar las condiciones de calidad de la red donde es prestado el servicio; otros estudios usan la combinación de ambas aproximaciones para refinar los modelos propuestos.

Es importante resaltar que la métrica de QoS más usada en los estudios es la escala absoluta de opinión media (i.e. MOS); sin embargo, nuevas propuestas ajustan esta escala a las necesidades específicas del estudio (e.g. SSIM, vMOS, CSAT).

Finalmente, la evaluación de calidad no es tomada como un todo; por el contrario, es evaluada en términos de condiciones puntuales de parámetros de calidad de la red y de la aplicación específica. En consecuencia, la métrica de evaluación de calidad está definida en términos de percepción y no en términos de la experiencia del usuario al momento de consumir un servicio.

### 3.2.6.7. Parámetro de medición de calidad

Los parámetros de calidad varían de acuerdo con el tipo de servicio analizado. De manera general, los estudios se centran en parámetros de red y de aplicación (i.e. NQoS y AQoS). Los primeros consideran condiciones de red que afectan notablemente la prestación del servicio (e.g. latencia, *jitter*, ancho de banda, velocidad de descarga, pérdida de paquetes); los segundos, relacionados con aspectos técnicos de la aplicación que ofrece el servicio (e.g. tasa de bits, tasa de tramas, resolución del contenido, duración del video).

Finalmente, parámetros de calidad de contexto, de interfaz o dispositivo y de usuario, empiezan a ser tenidos en cuenta para optimizar los modelos propuestos en términos de un valor estimado más representativo de la experiencia del usuario al momento de consumir un servicio OTT.

### 3.2.6.8. Identificación y designación de elementos conceptuales del modelo

Teniendo en cuenta la síntesis descriptiva de los datos extraídos de los estudios seleccionados, se procede con la designación de los elementos conceptuales del modelo QoE para servicios OTT. En ese sentido, los elementos conceptuales se determinan por la relación conceptual existente entre las categorías base; esto es: relación conceptual QoE-QoS, relación conceptual QoS-OTT, y relación conceptual QoE-OTT.

Estas relaciones han sido etiquetadas con el ánimo de designar los elementos conceptuales del modelo QoE para OTT. En consecuencia, se tiene:

- Perfil de servicio (i.e. Relación conceptual QoS-OTT): Relaciona la información de parámetros, las condiciones, las restricciones de un servicio OTT sobre su aprovisionamiento en la red del operador;

es decir, evaluación de las condiciones de QoS para el correcto funcionamiento y desempeño de un servicio OTT.

- Perfil de usuario (i.e. Relación conceptual QoE-OTT): relaciona la información de configuración, preferencias, comportamiento, y restricciones que tiene un usuario al momento de consumir un servicio OTT; es decir, evaluación de la experiencia de un usuario en relación con el consumo de un servicio OTT.
- Perfil paramétrico (i.e. Relación conceptual QoE-QoS): relaciona la información de la red en términos de calidad del servicio con la percepción de calidad del usuario a través de la parametrización de sus componentes; es decir, evaluación de la percepción de calidad de un usuario en relación con la calidad de servicio ofrecida.

La Tabla 3.2.12 relaciona la salida de la etapa SLR-2D con los productos generales de la etapa y particulares del módulo Elementos conceptuales.

**Tabla 3.2.12.** Productos de la etapa SLR-2D y del módulo Elementos conceptuales.

Salidas SLR-2D	Producto general de la etapa	Producto particular del módulo
Análisis cualitativo por concepto.	Síntesis de los datos extraídos	Sección 3.2.6 (e.g. modelo propuesto, meta, parámetro de medición, métrica de evaluación)
Presentación de resultados		Identificación y designación de los elementos conceptuales

### 3.2.7. Reporte (SLR-3)

Para la presentación de los resultados obtenidos, la Tabla 3.2.13 expone las revistas más representativas para someter una publicación científica en relación con el modelo QoE para servicios OTT.

**Tabla 3.2.13.** Revistas científicas más representativas en el contexto del aprovisionamiento de QoE para servicios OTT.

Nombre	Documentos	Citaciones
COMPUTER NETWORKS	33	275
MULTIMEDIA TOOLS AND APPLICATIONS	30	95
IEEE ACCESS	29	15
WIRELESS PERSONAL COMMUNICATIONS	26	9
IEEE COMMUNICATIONS MAGAZINE	22	615
COMPUTER COMMUNICATIONS	21	51
IEEE TRANSACTIONS ON VEHICULAR TECHNOLOGY	21	325
IEICE TRANSACTIONS ON COMMUNICATIONS	21	46
TELECOMMUNICATION SYSTEMS	17	140
INTERNATIONAL JOURNAL OF COMMUNICATION SYSTEMS	16	30

Datos tomados del módulo Evolución QoE en OTT

La Tabla 3.2.14 relaciona la salida de la etapa SLR-3 con los productos generales de la etapa y particulares del módulo Elementos conceptuales.

**Tabla 3.2.14.** Productos de la etapa SLR-3 y del módulo Elementos conceptuales.

Salidas SLR-3	Producto general de la etapa	Producto particular del módulo
Ventana de presentación	Lista de revistas	Tabla 3.2.13
Presentación de resultados		

### 3.2.8. Síntesis del módulo Elementos conceptuales

El módulo de Elementos conceptuales presenta la definición de los perfiles del modelo QoE para servicios OTT requeridos en la estimación del nivel de QoE dentro de la infraestructura de red de una Telco. En ese sentido, se tiene que:

- Los perfiles de servicio, usuario y paramétrico representan la relación conceptual que existe entre las categorías conceptuales QoE, QoS, y OTT. La relación conceptual QoS-OTT (i.e. perfil de servicio) relaciona la información de parámetros (e.g. elementos descriptores de flujo), las condiciones (e.g. tipo de red en la que es provisto), y las restricciones de un servicio OTT sobre su aprovisionamiento en la red del operador (e.g. políticas de QoS). La relación conceptual QoE-OTT (i.e. perfil de usuario) relaciona la información de configuración (e.g. plan contratado del servicio), preferencias del usuario (e.g. necesidades de consumo), comportamiento del usuario (e.g. tiempo de consumo), y restricciones que tiene un usuario al momento de consumir un servicio OTT (e.g. políticas de aprovisionamiento); es decir, evaluación de la experiencia de un usuario en relación con el consumo de un servicio OTT. La relación conceptual QoE-QoS (i.e. perfil paramétrico) relaciona la información de la red en términos de calidad del servicio con la percepción de calidad del usuario a través de la parametrización de sus componentes; es decir, evaluación de la percepción de calidad de un usuario en relación con la calidad de servicio ofrecida.
- Cada perfil del modelo o relación conceptual tiene diferentes aproximaciones que relacionan sus características; por ejemplo: un modelo de caracterización y clasificación de tráfico permite, a partir de la medición de parámetros del flujo (e.g. paquetes, duración), determinar una clase de servicio sobre la cual un tipo de tráfico es tratado sobre la red. Un modelo de experiencia de usuario permite, a partir de las emociones y sus necesidades, caracterizar el comportamiento del consumo y grado de satisfacción del usuario al momento de consumir un conjunto de servicios. Y un modelo de correlacional QoS-QoE permite identificar un nivel de QoE del usuario bajo condiciones específicas de QoS entregadas por una Telco al momento de consumir sus servicios.
- Los modelos propuestos en cada uno de los perfiles consideran diferentes técnicas de aprendizaje automático; por ejemplo: para modelos de clasificación y caracterización de tráfico se pueden emplear árboles de decisión, teorema bayes, y vecinos más cercanos; para modelos de evaluación de la experiencia se pueden emplear algoritmos de visión por computadora o procesamiento de lenguaje natural; para modelos de correlación QoE-QoS, se usan técnicas como redes neuronales o de perceptrón multicapa. De igual manera, para cada modelo se utilizan métricas representativas. Un modelo basado en el perfil de servicio podría emplear métricas como retardo y pérdida de paquetes para evaluar el desempeño de los servicios. Un modelo de experiencia de usuario métricas como el cumplimiento de las expectativas puede ser tenida en cuenta para verificar su validez. Y para un modelo de correlación, la MOS es la base para determinar la percepción de la calidad del servicio entregado.

Finalmente, otro conjunto de elementos representativos permitió definir los elementos conceptuales del modelo; se resaltan:

- Servicio o aplicación: característica que representa el servicio o la aplicación usada como elemento de análisis del modelo propuesto.
- Dominio de aplicación: característica que representa el tipo de red usada como escenario de experimentación, y modalidad del escenario de prueba.
- Conjunto de datos: característica que representa el conjunto de datos obtenidos o generados para modelar su comportamiento.

- Meta: característica que representa la finalidad del estudio; es decir, el uso práctico de la propuesta.

### 3.3. RECAPITULACIÓN

En este capítulo se presentó el desarrollo del macro-componente Conceptualización de acuerdo con el proceso definido en la estructura metodológica. Para este macro-componente se llevaron a cabo dos iteraciones. La primera, centrada en la comprensión del aprovisionamiento de la QoE para servicio OTT; la segunda, orientada en la definición de los elementos conceptuales del modelo. En ese sentido, se tiene:

- El módulo de Evolución QoE en OTT tiene como resultado un mapa estratégico que indica la evolución científica y tecnológica en el aprovisionamiento de la QoE para servicios OTT bajo condiciones de QoS. Este mapa estratégico establece la base conceptual para desarrollar marcos de referencia en la definición de sistemas de modelamiento de QoE, de sistemas de gestión de la QoE, de sistemas de aprovisionamiento de QoE centradas en el usuario, de sistemas de control y reasignación de recursos de red, y modelos de negocio centrados en la experiencia. La interpretación del mapa estratégico se realiza por medio del análisis de sus cuadrantes: temas motores, temas de alto desarrollo y aislados, temas emergentes o en declive, y temas transversales y básicos.
- El módulo de Elementos conceptuales tiene como resultado la descripción de los perfiles que caracterizan el aprovisionamiento de la QoE para servicios OTT a partir de unas condiciones específicas de QoS. Un perfil de servicio centrado en analizar el comportamiento de tráfico en la infraestructura de red, e identificar las condiciones de QoS entregadas por una Telco durante el consumo de los servicios; un perfil de usuario orientado en la comprensión del comportamiento de consumo de servicios OTT por parte de usuario en términos de sus preferencias; y un perfil paramétrico que relaciona la percepción de la calidad de los servicios OTT a partir de unas condiciones de tráfico y de QoS entregadas por una Telco en el consumo de servicios OTT.

En síntesis, este capítulo presenta la base conceptual sobre la cual se define un modelo de estimación de la QoE a partir de unas condiciones específicas de QoS entregadas por una Telco en el consumo de servicios OTT. En particular, esta base conceptual permitirá el desarrollo de marcos de referencia en la definición de sistemas de gestión de la QoE dentro de la infraestructura del operador. Por ello, los perfiles definidos están alineados con el ánimo de alcanzar una meta específica: monitorizar la QoE en la infraestructura de red de un operador de telecomunicaciones.

## CAPÍTULO 4. MACRO-COMPONENTE OPERACIONAL

En el presente capítulo se describe el modelo correlacional QoS-QoE que tiene como objetivo estimar un valor o nivel de QoE en el aprovisionamiento de servicios OTT a partir de un comportamiento de consumo del usuario y bajo unas condiciones de QoS presentes en el tráfico de red del operador. En ese sentido, se presenta un escenario general para la comprensión del modelo, una descripción general del modelo, la finalidad del modelo, y su construcción a partir de la definición de los perfiles de servicio, de usuario, y paramétrico que lo componen.

El desarrollo del modelo parte de los resultados obtenidos del macro-componente Conceptualización (Capítulo 3), específicamente de los productos de las etapas SM-5 y SLR-3. Al final, se propone un escenario de explotación o despliegue del modelo correlacional de acuerdo con la finalidad definida.

### 4.1. ESCENARIO GENERAL

La Figura 4.1.1 presenta un escenario general de aplicación como descripción del contexto de la QoE en el aprovisionamiento de servicios OTT.

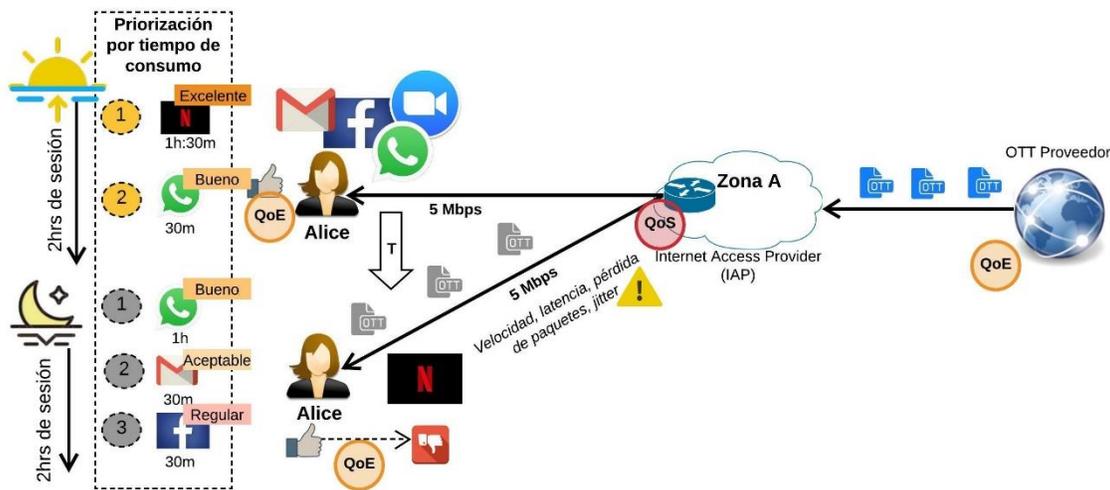


Figura 4.1.1. Escenario General de aplicación QoE

El usuario Alice está dentro de una sesión donde consume una serie de servicios OTT. Para este usuario, cada uno de los servicios consumidos durante la sesión tienen una prioridad diferente, la cual estará determinada por el tiempo de consumo del servicio. En consecuencia, se espera que, para el servicio con mayor consumo durante la sesión, se tengan los mejores niveles de QoE (e.g. bueno o excelente); e.g., el usuario Alice durante una sesión de dos horas en la mañana, podría haber consumido un servicio como Netflix durante 1h:30m, y WhatsApp durante 30min, por lo que se esperaría que el servicio de Netflix tuviera los niveles más altos de QoE. Lo anterior podría modificarse durante una sesión de la tarde para el mismo usuario, donde el servicio más consumido durante dos horas de sesión podría ser WhatsApp, seguido del correo electrónico y Facebook (e.g. 1h, 30min, 30min, respectivamente); para este caso, los valores más altos de QoE se esperarían para el servicio de mensajería (i.e. WhatsApp).

Teniendo en cuenta que el grado de ocupación de la red del operador es variable y que su estructura condiciona el aprovisionamiento de los servicios, un usuario podría experimentar congestión en algún momento del día

cuando el tráfico que transita por la red de su operador es alto. En efecto, la congestión presentada en la red, ocasiona que los paquetes con destino al usuario sufran efectos como reducción en la velocidad, latencia, pérdida de paquetes y *jitter*. Estos parámetros medibles en la red determinan la QoS entregada al usuario.

La QoS entregada al usuario Alice se verá reflejada en el servicio de varias maneras; e.g., si un usuario presenta una QoS entregada baja, y este está consumiendo algún servicio de *video streaming* (e.g. Netflix), es posible que la calidad de la imagen disminuya, o que el servicio detenga su reproducción al no tener los paquetes suficientes para lograr una correcta visualización. En realidad, la experiencia general del servicio se verá deteriorada al momento de experimentar los efectos de una baja QoS, produciendo un malestar generalizado del servicio por parte de sus usuarios.

Para el escenario de aplicación representado en la Figura 4.1.1 se tiene que el usuario Alice durante las primeras horas de la mañana, donde no se presenta congestión en la red del operador, percibe una calidad del servicio de excelente y buena para los servicios de Netflix y WhatsApp, respectivamente. Pasado un tiempo, Alice cambia su comportamiento de consumo, priorizando el servicio WhatsApp sobre el servicio de correo electrónico y Facebook; para este momento del día (tarde-noche), la red del operador presenta altos niveles de congestión, entregando a Alice una QoS deteriorada por la reducción en la velocidad de transmisión, latencia, pérdida de paquetes y *jitter*. En consecuencia, Alice nota que sus servicios empiezan a experimentar fallas como tiempos elevados de carga, video llamada borrosa, y mensajes no enviados al instante; por consiguiente, Alice tiene una percepción de la calidad de sus servicios de buena, aceptable, y regular para los servicios priorizados por su comportamiento de consumo (WhatsApp, correo, Facebook, respectivamente)

De acuerdo con este escenario, se desarrolla un modelo correlacional QoS-QoE que estime un nivel de QoE con base en el comportamiento de consumo de los usuarios y de condiciones de QoS específicas en la red del operador. De esta manera, el operador puede gestionar la QoE con el ánimo de ofrecer unidades de negocio centradas en la experiencia de sus usuarios, monitorizar la QoE para optimizar la asignación de recursos de red sin perjudicar la satisfacción de sus usuarios, y proveer mecanismos de aprovisionamiento de servicios OTT con una buena relación QoE-QoS.

## 4.2. MODELO CORRELACIONAL QOS-QOE

### 4.2.1. Descripción general

La Figura 4.2.1 presenta el modelo correlacional QoS-QoE en el aprovisionamiento de servicios OTT. El modelo recibe como entrada el comportamiento de consumo del usuario que incluye las condiciones de QoS específicas en la red del operador y, durante la fase de creación, la percepción que el usuario tiene sobre el aprovisionamiento de los servicios; como salida, el modelo entrega un valor o nivel de QoE del usuario luego de consumir sus servicios de preferencia.

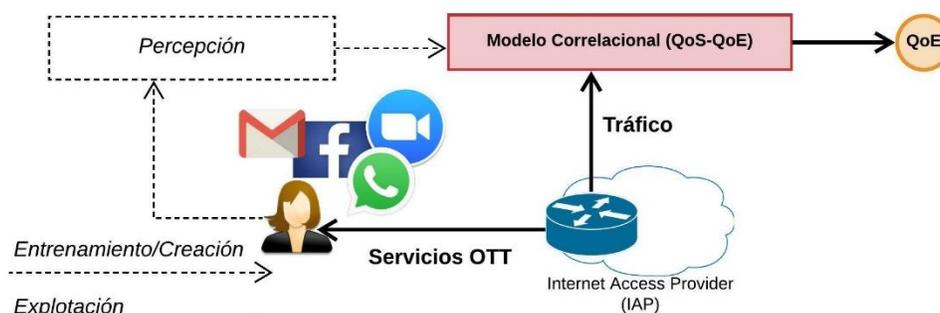


Figura 4.2.1. Modelo correlacional QoS-QoE

Desde el punto de vista del usuario, el comportamiento de consumo está dado por la cantidad de servicios visualizados, el tiempo de uso de los servicios durante una sesión, y el tiempo de duración de una sesión. La percepción de calidad de los servicios por parte del usuario está determinada por la evaluación que este realiza para cada servicio luego de terminar su respectiva sesión (e.g. Excelente, buena, regular).

Desde el punto de vista del operador, el comportamiento de consumo de sus usuarios está dado por los descriptores de tráfico en su red de aprovisionamiento de servicios (e.g. paquetes entregados, bits por segundo, flujos, conexiones IP origen-destino, puertos). Por su parte, la percepción del usuario sobre la calidad del servicio está determinada por un valor general luego de consumir varios servicios durante una sesión (e.g. 3.0, 4.0, 5.0). Este valor de la percepción de la calidad del servicio (i.e. QoS, QoE Percibida), calculado a partir de las evaluaciones parciales por parte del usuario, determina el nivel de QoE del usuario luego de una sesión de aprovisionamiento de servicios OTT.

Por otro lado, las condiciones de QoS presentes en la red del operador son determinadas por la configuración del sistema de QoS en los tramos donde el tráfico está siendo monitorizado.

Es importante resaltar que, para la fase de explotación del modelo, este solo recibe la entrada de tráfico para determinar el valor de la QoE; mientras que la entrada de percepción del usuario es empleada en la fase de entrenamiento del modelo o para una actualización futura de acuerdo con los cambios de comportamiento de consumo de los usuarios.

#### 4.2.2. Finalidad del modelo correlacional QoS-QoE

El modelo correlacional QoS-QoE puede ser empleado por un operador en su sistema de gestión de aplicación y de red orientado a la QoE, como el propuesto por Schatz, R. et al. en [174]. Para ello, se ha definido un módulo de monitorización y otro de control con el objeto de explotar, por parte del operador, el modelo correlacional dentro de su red de aprovisionamiento de servicios OTT (Figura 4.2.2).

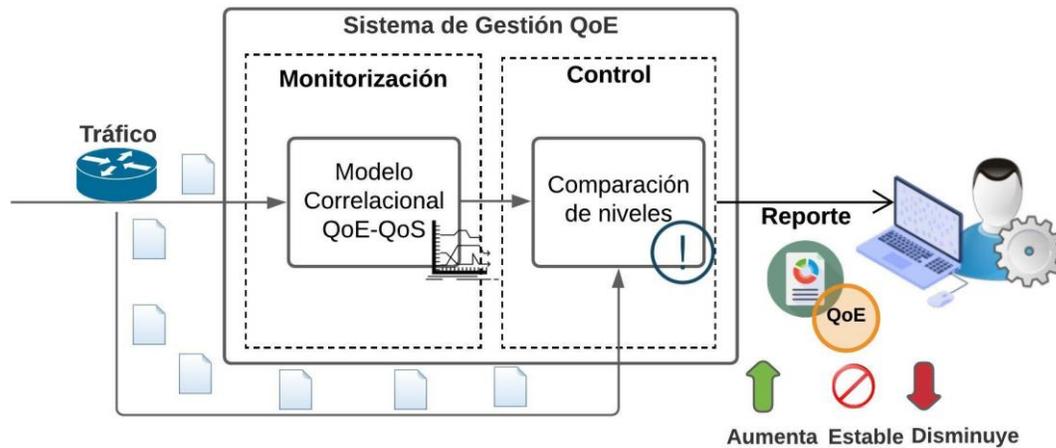


Figura 4.2.2. Visión general de la explotación del modelo correlacional QoS-QoE

El módulo de *Monitorización* realiza la medición de los flujos bidireccionales de conexión Usuario – Servicio y estima un nivel de QoE de sus usuarios por cada flujo monitorizado; como entrada, este módulo recibe el tráfico de la red proveniente del enrutador que agrupa a un conjunto de usuarios, y como salida, este módulo entrega un nivel estimado de QoE para sus usuarios.

El módulo de *Control* permite compara el nivel de QoE estimado y el nivel QoE esperado por la Telco, con el objeto de verificar el cumplimiento de la QoS configurada en el nodo de recolección de tráfico; como entrada, este módulo recibe los niveles estimados y esperados de la QoE para cada uno de los usuarios, y como salida, se entrega un reporte donde se visualiza si determinado usuario ha mejorado, mantenido, o disminuido la QoE de acuerdo con la QoS entregada por el operador a cada uno de sus usuarios.

La Sección 4.2.4. explotación o despliegue del modelo, ofrece más detalles acerca de la explotación del modelo correlacional QoS-QoE.

### 4.2.3. Construcción del modelo de correlación QoS-QoE

El modelo correlacional QoS-QoE tiene como objetivo predecir un valor o nivel de QoE en el aprovisionamiento de servicios OTT a partir de un comportamiento de consumo del usuario y bajo unas condiciones de QoS presentes en el tráfico de red del operador. Para ello, se han construido diferentes modelos a partir del entrenamiento de diversos algoritmos de aprendizaje automático (e.g. Árboles de decisión, regresión lineal Ridge, KNN, Redes Neuronales). Adicionalmente, la construcción del modelo de correlación implementa los elementos conceptuales definidos en el macro-componente de Conceptualización; esto es:

- Perfil de servicio: Describe las características de comportamiento de tráfico en el aprovisionamiento de servicios OTT.
- Perfil de usuario: Describe las características del comportamiento y preferencias de consumo de servicios OTT de los usuarios.
- Perfil paramétrico: Presenta la valoración de la evaluación final de la calidad de la experiencia de acuerdo con el comportamiento de tráfico y el comportamiento de consumo del usuario en el aprovisionamiento de servicios OTT.

La fase de creación de los modelos está conformada por diferentes módulos, los cuales implementan tareas específicas de la metodología CRISP-DM y cubren los tres perfiles descritos (ver Figura 4.2.3).

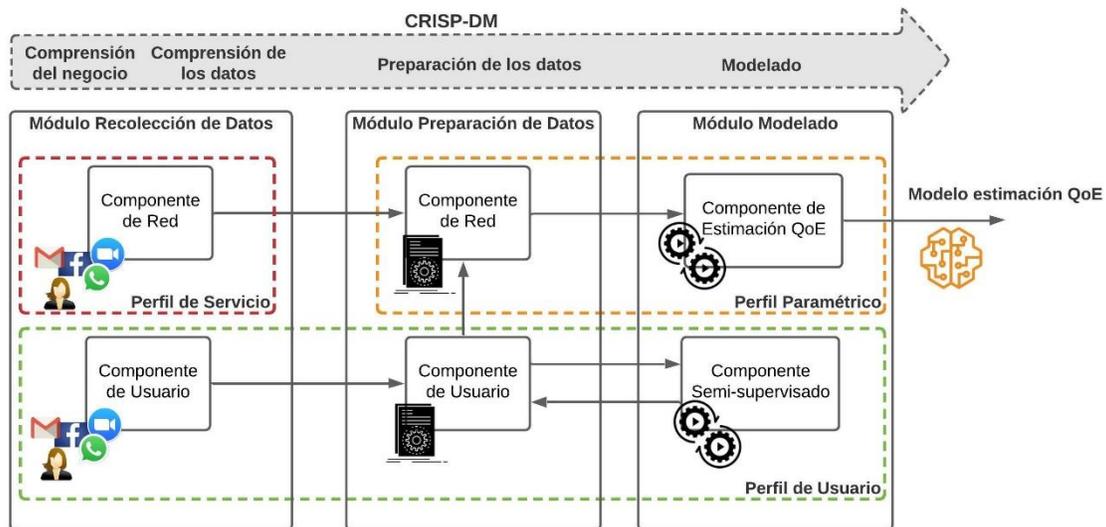


Figura 4.2.3. Módulos de construcción del modelo correlacional QoS-QoE

El módulo de *Recolección de datos* se encarga de obtener la información necesaria para construir el modelo de predicción QoE del usuario luego de consumir diferentes servicios durante una sesión. Para ello, se han definido dos componentes. El primero, un Componente de red encargado de reunir datos de tráfico y las

condiciones de QoS presentes en cada uno de los flujos que se tienen entre las conexiones de los usuarios con sus servicios. El segundo, un Componente de usuario donde se reúnen los datos de consumo y la percepción de calidad de cada servicio.

El módulo de *Preparación de datos* se encarga de transformar los datos recolectados en datos estructurados y válidos para el entrenamiento de algoritmos de aprendizaje automático. Para ello, se han definido dos componentes. El primero, un componente de preparación de datos de usuario donde se definen las técnicas y métodos de transformación para los datos de consumo, y se calcula un valor de QoS general por cada sesión de usuario. El segundo, un componente de preparación de datos de red donde se definen las técnicas y métodos de transformación para los datos de tráfico, y se relaciona la percepción de la calidad del servicio para cada uno de los flujos presentes entre el usuario y los servicios consumidos en cada una de las sesiones.

El módulo de *Modelado* se encarga de ajustar un modelo de estimación de QoE basándose en algoritmos de aprendizaje automático. Para el perfil de usuario, se implementa un componente semisupervisado con el ánimo de etiquetar todas las sesiones de usuario que fueron monitorizadas; mientras que, para el perfil paramétrico, un componente de estimación se encarga de generar el modelo final para determinar el valor de la QoE a partir del comportamiento del tráfico en el aprovisionamiento de servicios OTT.

Por otro lado, los perfiles del modelo están caracterizados de la siguiente manera:

El *perfil de servicio* determina las características principales que describen del comportamiento del tráfico de la red en el aprovisionamiento de servicios OTT, y define los lineamientos para estructurar el conjunto de datos de tráfico recolectado. Al final, un entendimiento del negocio y de los datos de tráfico permite determinar las estrategias de preparación del conjunto de datos empleados en el entrenamiento del modelo de predicción de la QoE.

El *perfil de usuario* determina las características que describen el comportamiento de consumo y preferencias del usuario al momento de consumir servicios OTT. Para ello, los datos recolectados son analizados, estructurados y procesados. Al final, un conjunto de datos de usuario con valoración de la percepción de la calidad del servicio en cada una de las sesiones monitorizadas, permite etiquetar un conjunto de datos bidireccionales de tráfico dentro de la red de aprovisionamiento de servicios OTT.

El *perfil paramétrico* presenta la relación entre los descriptores que representan el comportamiento del tráfico y el descriptor que representa la valoración de la percepción de la calidad de los servicios OTT consumidos por los usuarios en cada una de sus sesiones. Al final, un modelo de estimación de la QoE es obtenido a partir del entrenamiento de algoritmos de aprendizaje automático.

#### 4.2.3.1. Módulo de Recolección de datos

La Figura 4.2.4 presenta la implementación del módulo de Recolección de datos a través de los bloques Netflow y QoE\_MOS para los componentes de red y de usuario, respectivamente.

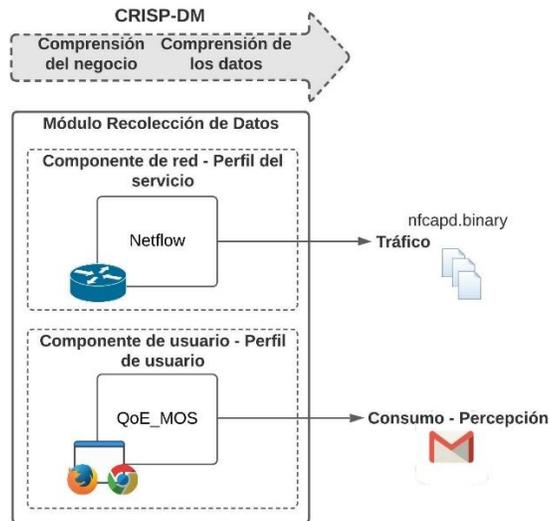


Figura 4.2.4. Módulo de Recolección de datos

El bloque de *Netflow* representa el método implementado para recolectar los datos de tráfico de los usuarios. El protocolo Netflow reúne datos que describen las conexiones entre los usuarios y los servicios que estos consumen (e.g. IP destino, IP origen, Protocolo, Paquetes) [175]. Adicionalmente, el descriptor del Tipo de Servicio (ToS) capturado en las conexiones usuario-servicio determinan el tratamiento QoS para cada flujo específico.

El bloque *QoE\_MOS* representa el método implementado para recolectar los datos de consumo y percepción de la calidad de los usuarios. Este método consiste en la generación de una aplicación particular que monitoriza la sesión del usuario y solicita la calificación absoluta de 5 puntos como valor MOS de la QoSP para los servicios de mayor consumo (i.e. ACR, *Absolute Category Rating*).

Los anteriores bloques fueron desplegados en un escenario de recolección de datos para el centro informático y para las salas informáticas de la UC3M. Los datos recolectados del escenario de prueba son de dos tipos: de red y de percepción de la calidad. El primero, presenta datos de tráfico de red en cada uno de los equipos monitorizados; el segundo, contiene la evaluación dada por cada usuario luego de haber consumido servicios de internet. La Figura 4.2.5 presenta el escenario de recolección de los datos (ver Anexo A para más detalles).

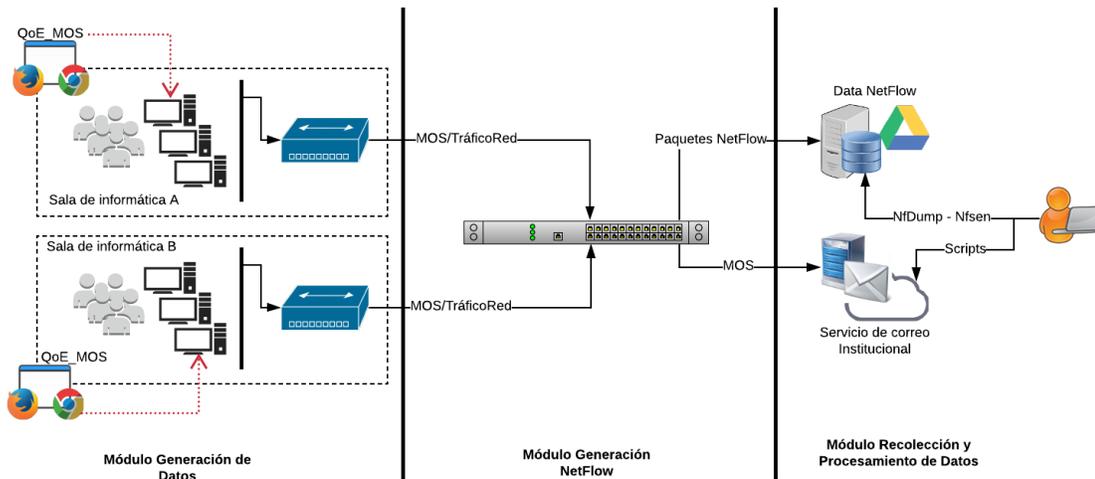


Figura 4.2.5. Escenario de recolección de datos – Tráfico de red y percepción de la calidad.

El escenario de recolección de los datos está compuesto de tres (3) módulos. El primero, *Generación de Datos*, está conformado por los usuarios finales que consumen servicios de internet (e.g. Facebook, Youtube, Instagram, mail). El segundo, *Generación NetFlow*, encargado de producir los paquetes NetFlow a partir del tráfico de red generado por los usuarios finales. De igual manera, este módulo envía la información de tráfico de red y la evaluación de los usuarios luego de haber consumido un conjunto de servicios de internet (i.e. evaluación MOS). Finalmente, el módulo de *Recolección y Procesamiento de Datos* se encarga de recibir y procesar los datos de evaluación de calidad percibida y de tráfico de red que serán empleados para la definición del modelo de predicción de la QoE a partir de la construcción de los perfiles de servicio, usuario y paramétrico, para un grupo de usuarios que consumen servicios OTT bajo condiciones específicas de QoS de la red.

Los datos de tráfico de red corresponden a la monitorización de flujos caracterizada por el protocolo Netflow [175], los cuales fueron recolectados con el conjunto de herramientas dispuestas por nfdump [176] y representados como archivos planos binarios de rápida escritura (i.e. archivos binarios nfcapd). Los datos de percepción de la calidad fueron generados por los usuarios a través de la aplicación QoE-MOS diseñada y desarrollada en el marco de la tesis de doctorado (ver anexo A). Estos datos fueron almacenados en el servidor de correo electrónico para su posterior procesamiento.

**A. Componente de red – perfil de servicio**

La Figura 4.2.6 presenta la implementación del Componente de red del módulo de Recolección de datos de la Figura 4.2.4. El bloque *Netflow* recolecta en archivos planos binarios los descriptores que representan el comportamiento del tráfico de la red a través de la monitorización del nodo recolector (i.e. enrutador). Los archivos binarios son almacenados para su posterior lectura, análisis y procesamiento.

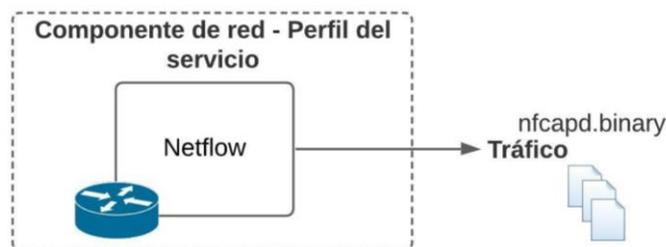


Figura 4.2.6. Componente de red – perfil de servicio (Módulo Recolección de datos)

### i. Comprensión del negocio

La monitorización de la red es una actividad bastante desarrollada en el contexto de las telecomunicaciones, con el objetivo de detectar algún problema dentro de una sección de la red de aprovisionamiento de servicios. En particular, la gestión de redes de telecomunicaciones emplea este tipo de procedimiento para el reconocimiento, exploración, y control de los flujos de tráfico que transitan en la red.

La monitorización de tráfico puede ser dividida en dos categorías: activa y pasiva [177]. La primera, emplea técnicas para inyectar tráfico en la red con el ánimo de obtener diferentes mediciones; la segunda, observa el comportamiento del tráfico a través de un punto de control. Para la monitorización pasiva, dos enfoques son ampliamente conocidos. Un enfoque orientado a la captura de paquetes, el cual requiere recursos elevados de procesamiento y almacenamiento, y un enfoque mucho más escalable en redes de alta velocidad donde los paquetes son agregados en flujos y posteriormente exportados para su análisis [177]. Para este último enfoque, los protocolos de monitorización de facto son Netflow y IPFIX [178].

El protocolo Netflow reúne información de tráfico por medio de descriptores obtenidos del procesamiento de los encabezados de los paquetes que transitan por el nodo recolector [175]. Dentro de los descriptores que pueden ser monitorizados, existe uno de especial interés para el contexto del modelo de correlación, el descriptor *ToS*, que determina la configuración sobre cómo los dispositivos de la red por donde transitará cada uno de los flujos deben aplicar las reglas de QoS para cada uno de los paquetes que pertenecen a un flujo específico [179].

El descriptor *ToS* capturado por el protocolo Netflow de Cisco debe ser entendido como el byte *ToS* del encabezado de paquetes IPv4 mapeado al campo de Servicios Diferenciados (DS, *Differentiated Services*) [180]. En efecto, el campo *ToS* de IPv4 definido en el RFC 791 [181] fue reemplazado por el campo DS en el RFC 2474 [182]; en consecuencia, solo 6 bits del encabezado IPv4 del campo DS son tenidos en cuenta para marcar el tráfico con cierta política de QoS (i.e. punto de código DS – DSCP; ver Figura 4.2.7). Por lo tanto, el máximo valor del descriptor *ToS* que es posible leer para el campo DSCP es de 252 en sistema decimal (el bit 7 es el menos significativo).

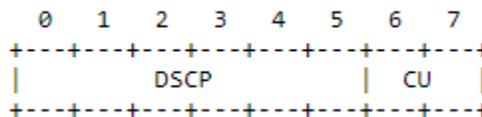


Figura 4.2.7. Campo DS  
Fuente: RFC 2474 [182]

La configuración del DSCP determina la manera en que los dispositivos de red aplican las políticas de QoS para cada una de las clases de servicio definidas en la RFC 4594 [183]. Estas clases de servicios determinan las categorías en las que cada tipo de tráfico es clasificado dentro de la red para su posterior control y tratamiento por los nodos que soporten gestión de la QoS por DSCP (i.e. enrutadores de frontera).

Las clases de servicio definidas responden a los requerimientos de las categorías de QoS centradas en el usuario (ITU-T G.1010 [184]) y a unos parámetros específicos de QoS (i.e. pérdida de paquetes, retardo y variación del retardo); por ejemplo, un tipo de tráfico o clase de servicio generado por una aplicación de tiempo real (e.g. videojuegos en línea), es considerado como una categoría de QoS interactiva (ITU-T G.1010), y con una tolerancia baja para la pérdida de paquetes, muy baja en el retardo, y baja en la variación del retardo [185]. En consecuencia, cada clase de servicio es marcada con un código DSCP que determina su tratamiento dentro de la red (e.g. prioritario y de bajo descarte); sin embargo, para los servicios que no son controlados y gestionados por el operador (i.e. Servicios OTT), el tráfico generalmente es marcado con la opción por defecto de mejor esfuerzo (i.e. código DSCP igual a 0 en decimal), por lo que se requiere una diferenciación del tráfico

para esta categoría que sea mapeado a otra clase de servicio con más privilegios. Una aproximación de un clasificador QoS para servicios OTT fue propuesta en el marco de la presente tesis de doctorado en [186].

## ii. Comprensión de los datos

### ➤ Descripción de los datos

Los datos de tráfico fueron obtenidos a través de la monitorización de flujos con la herramienta nfdump (i.e. conjunto de herramientas para coleccionar y procesar datos tipo Netflow). Los archivos binarios generados contienen los registros de los flujos que describen el comportamiento del tráfico de red que transita sobre el dispositivo de reenvío de paquetes (e.g. enrutador, conmutador). La Tabla 4.2.1 presenta el resumen de los datos recolectados.

**Tabla 4.2.1.** Descripción general de datos de tráfico de red por monitorización de flujos.

Periodo (2019)	Archivos		Periodo de recolección (i.e Monitorización)	Registros o flujos
	Formato	Cantidad		
Mes 1 - Ene	nfcapd.201901010000 - nfcapd.201901312355	8.928	5 min	1.450.025 (162 prom.)
Mes 2 - Feb	nfcapd.201902010000 - nfcapd.201902282355	8.064	5 min	4.065.617 (504 prom)
Mes 3 - Mar	nfcapd.201903010000 - nfcapd.201903312355	8.916	5 min	5.767.376 (646 prom.)
Mes 4 - Abr	nfcapd.201904010000 - nfcapd.201904302355	8.640	5 min	4.267.231 (493 prom.)
Mes 5 - May	nfcapd.201905010000 - nfcapd.201905312355	8.928	5 min	2.502.334 (280 prom.)
<b>Totales</b>		<b>43.476</b>		<b>18.052.583 (415 prom.)</b>

Los campos de la Tabla 4.2.1 deben ser entendidos de la siguiente manera:

- Periodo: espacio temporal donde fueron generados y recolectados los datos.
- Archivos: formato y cantidad de los datos binarios recolectados de los flujos monitorizados por el dispositivo de reenvío de paquetes (i.e. enrutador). El formato de estos archivos binarios es nfcapd.YYMMDDHHMM.
- Tiempo de recolección: tiempo de recolección de los flujos generados por el dispositivo de reenvío de paquetes (i.e. 5 min por defecto de tiempo de monitorización).
- Registros o flujos: cantidad total de flujos por mes de recolección y cantidad de flujos promedio por archivo.

Finalmente, cada registro o flujo tiene un conjunto de elementos descriptores, los cuales representan información de los paquetes recolectados que comparten características específicas; esto es: cada flujo tiene un total de 48 descriptores, correspondientes a un subconjunto de la totalidad de elementos definidos por el protocolo Netflow (i.e. 79 tipos). La recolección de datos de los elementos descriptores depende de la configuración del dispositivo en el que se ha dispuesto el punto de observación.

### ➤ Exploración de los datos

Los datos recolectados contienen un conjunto de elementos descriptores que relacionan información de red y de configuración del punto de observación. En ese sentido, los datos recolectados tienen información representada por 48 parámetros, 11 de los cuales registran datos válidos para el análisis del comportamiento

de tráfico a partir de condiciones de flujo. Los parámetros restantes, tienen para todos sus registros un valor de 0, lo cual indica que dicha característica o descriptor no fue monitorizado o que el dispositivo no fue configurado para tal fin. La Tabla 4.2.2 presenta los descriptores con datos válidos para el análisis.

**Tabla 4.2.2.** Descriptores válidos de los flujos recolectados

ts	te	td	sa	da	sp	dp	pr	tos	ipkt	ibkt
Tiempo de inicio	Tiempo fin	Tiempo de duración	Dirección IP origen	Dirección IP destino	Puerto origen	Puerto destino	Protocolo de conexión IP	Tipo de servicio	Paquetes de entrada	Bytes de entrada

Con el ánimo de determinar el comportamiento del tráfico de red a partir de los parámetros de flujo, se realizó un conjunto de operaciones sobre los datos que permitiera obtener información más relevante; esto es: se calcularon estadísticas por mes y totales con base en los elementos descriptores más representativos (sa, da, tos), y se agregaron flujos por IP origen y destino (sa, da). Las estadísticas obtenidas corresponden a la cantidad de flujos (fl), paquetes por segundo (pps), bits por segundo (bps), bytes por paquete (bpp). Los descriptores *ipkt* y *ibyt* son recalculados de acuerdo con la configuración del formato de lectura y conversión de los archivos binarios, y designados como cantidad de paquetes (pkt) y cantidad de bytes (byt), respectivamente. De igual manera, los descriptores *ts* y *te* fueron desagregados en *ts1*, *ts2*, y *te1*, *te2*, respectivamente (ver Tabla 4.2.6).

La Tabla 4.2.3 presenta el subconjunto de datos obtenido luego de analizar los registros totales por mes y por la totalidad del periodo de monitorización.

**Tabla 4.2.3.** Subconjunto de datos y datos totales de tráfico.  
**Estadística por mes (i.e. mes a mes, 1 a 5)**

Nombre	Descripción	Archivo nuevo	Registros (Flujos analizados)
Srcip	Estadística por dirección IP origen y por mes	srcip-stat_0x.csv; x=[1, 5]	Mes 1: 134.492 (1.450.025) Mes 2: 127.814 (4.065.617) Mes 3: 132.224 (5.767.376) Mes 4: 110.439 (4.267.231) Mes 5: 117.889 (2.502.334)
Dstip	Estadística por dirección IP destino y por mes	dstip-stat_0x.csv; x=[1, 5]	Mes 1: 12.957 (1.450.025) Mes 2: 24.302 (4.065.617) Mes 3: 24.262 (5.767.376) Mes 4: 20.847 (4.267.231) Mes 5: 16.261 (2.502.334)
Tos	Estadística Tipo de Servicio por mes	tos-stat_0x.csv; x=[1, 5]	Mes 1: 50 (1.450.025) Mes 2: 56 (4.065.617) Mes 3: 48 (5.767.376) Mes 4: 51 (4.267.231) Mes 5: 49 (2.502.334)
Agregado srcip	Estadística de flujos agregados por dirección IP origen y por mes	srcip-agre_0x; x=[1, 5]	Mes 1: 134492 (1.450.025) Mes 2: 127.814 (4.065.617) Mes 3: 132.224 (5.767.376) Mes 4: 110.439 (4.267.231) Mes 5: 117.889 (2.502.334)
Agregado dst	Estadística de flujos agregados por dirección IP destino y por mes	dstip-agre_0x; x=[1, 5]	Mes 1: 12.957 (1.450.025) Mes 2: 24.302 (4.065.617) Mes 3: 24.262 (5.767.376) Mes 4: 20.847 (4.267.231) Mes 5: 16.261 (2.502.334)

Total	Totalidad de flujos no procesados con 15 descriptores por mes (i.e. fmt:%ts %te %td %sa %da %sp %dp %pr %tos %pkt %byt %fl %bpp %pps %bps)	total_0x; x=[1, 5]	Mes 1: 1.450.025 Mes 2: 4.065.617 Mes 3: 5.767.376 Mes 4: 4.267.231 Mes 5: 2.502.334
Estadística total por meses (i.e. periodo de 5 meses)			
Nombre	Descripción	Archivo nuevo	Registros (Flujos analizados)
Srcip	Estadística por dirección IP origen en todo el periodo	srcip-stat_total.csv	502. 217
Dstip	Estadística por dirección IP destino en todo el periodo	dstip-stat_total.csv	68. 325
Tos	Estadística tipo de servicio en todo el periodo	tos-stat_total.csv	71
Agregado srcip	Estadística de flujos agregados por dirección origen en todo el periodo	srcip-agre_total	502. 217
Agregado dst	Estadística de flujos agregados por dirección IP destino y por mes	dstip-agre_total	68. 325
Total	Totalidad de flujos no procesados con 15 descriptores en todo el periodo (i.e. fmt:%ts %te %td %sa %da %sp %dp %pr %tos %pkt %byt %fl %bpp %pps %bps)	total_todo	18.052.583

Finalmente, la Tabla 4.2.4 presenta un resumen de los datos estadísticos básicos para los atributos donde estos pueden ser calculados.

Tabla 4.2.4. Resumen datos estadísticos de descriptores de tráfico.

srcip-stat_total						
td	fl	ipkt	ibyt	ipps	ibps	ibpp
Min: 0	Min: 1	Min: 1	Min: 42	Min: 0	Min: 0	Min: 42
Max: 15878615.716	Max: 268745	Max: 30837890	Max: 44309968856	Max: 17593	Max: 205452106	Max: 1500
Media: 860419.462	Media:35.94	Media:1482.27	Media:1397256.2	Media:5.81	Media:8142.35	Media:82.9
DevStd:229273	6	9	83	3	5	66
9.829	DevStd:1936	DevStd:10924	DevStd:1352185	DevStd:39.	DevStd:45004	DevStd:187
	.252	5.076	79.772	063	1.071	.391

dstip-stat_total						
td	fl	ipkt	ibyt	ipps	ibps	ibpp
Min: 0	Min: 1	Min: 1	Min: 46	Min: 0	Min: 0	Min: 46
Max:16516852.272	Max: 384276	Max: 23496948	Max: 30340869698	Max: 5898	Max: 11061159	Max: 1479
Media:1390275.018	Media:264.2	Media:10895.3	Media: 9	Media:5.90	Media:3605.	Media:93.09
DevStd:294171	16	65	10270411.395	DevStd:44.	254	DevStd:100.
2.181	DevStd:6987	DevStd:34697	DevStd:42183794	851	DevStd:5218	DevStd:377
	.247	3.285	7.322		8.48	

tos-stat_total						
td	fl	ipkt	ibyt	ipps	ibps	ibpp
Min: 0	Min: 1	Min: 1	Min: 42	Min: 0	Min: 0	Min: 42
Max:16516925	Max:14397144	Max:63169594	Max:	Max: 119	Max: 266179	Max: 1492
.092	Media:257894.	0	549557761105	Media:2.9	Media:5785.	Media:327.
Media:837576	043	Media:1063465	Media:100246551	71	643	157
8.264	DevStd:17342	4.771	21.943	DevStd:15	DevStd:3279	DevStd:50
DevStd:55070	45.495	DevStd:760471	DevStd:66991238	.031	9.448	0.519
95.335		74.383	051.887			

Total_todo						
td	fl	ipkt	ibyt	ipps	ibps	ibpp
Min: 0	Min: 1	Min: 0	Min: 0	Min: 0	Min: 0	Min: 0
Max:1.952400	Max:1	Max:1.600000e+0	Max:2.300000	Max:4.406000e+	Max:5.272000e+	Max:1.500000e+
e+03	Media:1	6	e+09	04	08	03
Media:8.32768	DevStd:1	Media:4.123604e	Media:	Media:1.709289e	Media:6.173709e	Media:1.317885e
7		+01	3.887300e+04	+01	+04	+02
DevStd:		DevStd:1.611502	DevStd:2.114	DevStd:1.591641	DevStd:1.752926	DevStd:2.166150
5.741480e+01		e+03	015e+06	e+02	e+06	e+02

La información relacionada en las tablas 4.2.3 y 4.2.4 pertenece a descriptores de tráfico para flujos individuales (i.e. una sola dirección; ida o vuelta); de ahí que se hace necesario procesar estos flujos para obtener flujos bidireccionales que representen el tráfico entre dos entidades que comparten la misma información (i.e. pr, sa, da, sp, dp). En efecto, las sesiones de consumo de los usuarios generan interacciones bidireccionales entre estos y los servicios OTT, por lo cual se requiere tener datos que caractericen este comportamiento durante las sesiones de los usuarios. La Tabla 4.2.5 presenta la conversión de flujos individuales a flujos bidireccionales en términos de la dimensión de los datos.

**Tabla 4.2.5.** Cantidad de datos flujos individuales y bidireccionales de tráfico de red – Dimensión de los datos.

	Flujos individuales	Flujos bidireccionales
<b>Mes 1</b>	(1.450.025, 17): 1.450.025 flujos individuales con 17 descriptores válidos	(677.925, 17): 677.925 flujos bidireccionales con 17 descriptores válidos
<b>Mes 2</b>	(4.065.617, 17): 4.065.617 flujos individuales con 17 descriptores válidos	(952.994, 17): 952.994 flujos bidireccionales con 17 descriptores válidos
<b>Mes 3</b>	(5.767.376, 17): 5.767.376 flujos individuales con 17 descriptores válidos	(2.411.817, 17): 2.411.817 flujos bidireccionales con 17 descriptores válidos
<b>Mes 4</b>	(4.267.231, 17): 4.267.231 flujos individuales con 17 descriptores válidos	(1.545.840, 17): 1.545.840 flujos bidireccionales con 17 descriptores válidos
<b>Mes 5</b>	(2.502.334, 17): 2.502.334 flujos individuales con 17 descriptores válidos	(808.235, 17): 808.235 flujos bidireccionales con 17 descriptores válidos
<b>Total</b>	(18.052.583, 17): 18.052.583 flujos individuales con 17 descriptores válidos	(6.247.144, 17): 6.247.144 flujos bidireccionales con 17 descriptores válidos

**NOTA:** Los descriptores de tráfico válidos corresponden a aquellos descritos en la Tabla 4.2.2 más los descriptores generados como estadísticos de tráfico (i.e. fl, pps, bps, y bpp). Adicionalmente, los descriptores ts y te han sido separados cada uno en dos descriptores debido al mecanismo de lectura del archivo inicial (i.e. ts1, ts2, te1 y te2, respectivamente).

Para los flujos bidireccionales, la información descriptiva de los datos de tráfico, presentada en las tablas 4.2.6 a 4.2.8 y figuras 4.2.8 a 4.2.11, se recolectó a partir de la revisión del conjunto de datos obtenido luego del proceso de lectura y conversión de los archivos binarios (ver sección 4.2.3 literal F índice ii, archivo total\_all).

Tabla 4.2.6. Tipo de datos de los descriptores de tráfico.

Descriptor	Tipo de dato
ts1, ts2, te1, te2, sa, da	Object
td, dp	Float64
sp, pr, tos, pkt, byt, fl, bpp, pps, bps	Int64

Las tablas 4.2.7 y 4.2.8, y las figuras 4.2.8 a 4.2.11 solo relacionan aquellos datos donde es posible obtener la descripción estadística para los flujos bidireccionales de tráfico (i.e. datos numéricos).

	td	sp	dp	pr	tos	pkt	byt	fl	bpp	pps
count	6.247144e+06									
mean	9.865854e+04	3.616360e+04	1.069988e+04	7.083907e+00	3.989198e+01	5.993068e+01	5.352170e+04	2.889733e+00	1.190264e+02	8.593450e+00
std	7.653439e+05	2.198300e+04	1.637740e+04	3.337840e+00	6.496578e+01	5.126349e+03	7.399513e+06	3.095598e+01	2.163787e+02	7.194980e+01
min	0.000000e+00	0.000000e+00	0.000000e+00	1.000000e+00	0.000000e+00	1.000000e+00	1.000000e+00	4.200000e+01	1.000000e+00	0.000000e+00
25%	1.000000e-01	1.061200e+04	4.430000e+02	6.000000e+00	0.000000e+00	1.000000e+00	4.200000e+01	1.000000e+00	4.200000e+01	1.000000e+00
50%	2.000000e-01	4.515900e+04	3.370000e+03	6.000000e+00	0.000000e+00	1.000000e+00	4.200000e+01	1.000000e+00	4.200000e+01	5.000000e+00
75%	2.850000e+00	5.332200e+04	9.001000e+03	6.000000e+00	7.200000e+01	4.000000e+01	7.190000e+02	2.000000e+00	8.100000e+01	1.000000e+01
max	1.303401e+07	6.553500e+04	6.553500e+04	4.100000e+01	2.520000e+02	1.039419e+07	1.536078e+10	8.849000e+03	1.500000e+03	1.621000e+04

	bps
count	6.247144e+06
mean	1.954053e+04
std	7.822448e+05
min	0.000000e+00
25%	9.890000e+02
50%	2.080000e+03
75%	3.360000e+03
max	1.932485e+08

Figura 4.2.8. Estadística descriptiva de los datos de tráfico.

En la Figura 4.2.8, la existencia de valores mínimos de cero para algunos descriptores de tráfico representa un valor no válido producto de un error en las mediciones para dicho flujo bidireccional o la no monitorización del parámetro para dicho intervalo. Sin embargo, el descriptor *tos* con valor de cero, sí tiene un significado propio y válido dentro del tráfico monitorizado para cada flujo bidireccional.

	td	sp	dp	pr	tos	pkt	byt	fl	bpp	pps	bps
td	1.000000	-0.376201	-0.221500	0.129792	-0.259995	0.754656	0.749277	0.758330	0.714282	-0.690882	-0.499827
sp	-0.376201	1.000000	0.009349	0.214759	0.033897	-0.406604	-0.444946	-0.505939	-0.431903	0.248215	0.104095
dp	-0.221500	0.009349	1.000000	-0.025218	0.122518	-0.297444	-0.256525	-0.246181	-0.226224	0.150061	0.126731
pr	0.129792	0.214759	-0.025218	1.000000	-0.167908	0.141357	0.260575	0.028282	0.330612	-0.074727	0.049221
tos	-0.259995	0.033897	0.122518	-0.167908	1.000000	-0.299724	-0.312384	-0.305064	-0.307964	0.165100	0.088765
pkt	0.754656	-0.406604	-0.297444	0.141357	-0.299724	1.000000	0.903817	0.816299	0.847463	-0.466423	-0.218039
byt	0.749277	-0.444946	-0.256525	0.260575	-0.312384	0.903817	1.000000	0.839953	0.977844	-0.476924	-0.187844
fl	0.758330	-0.505939	-0.246181	0.028282	-0.305064	0.816299	0.839953	1.000000	0.793582	-0.528485	-0.330972
bpp	0.714282	-0.431903	-0.226224	0.330612	-0.307964	0.847463	0.977844	0.793582	1.000000	-0.457129	-0.141755
pps	-0.690882	0.248215	0.150061	-0.074727	0.165100	-0.466423	-0.476924	-0.528485	-0.457129	1.000000	0.885785
bps	-0.499827	0.104095	0.126731	0.049221	0.088765	-0.218039	-0.187844	-0.330972	-0.141755	0.885785	1.000000

Figura 4.2.9. Correlación de Spearman de descriptores de tráfico

Los valores de la Figura 4.2.9 de correlación indican una relación variada entre cada uno de los descriptores de tráfico (i.e. positiva y negativa). Valores de +1 presentan una relación positiva perfecta (i.e. valores diagonales de la tabla); valores de -1 presentan una relación negativa perfecta; mientras que valores de 0 indican que no hay relación.

En este caso, la mayoría de los valores presentan baja relación entre sus descriptores (i.e. valores de coeficiente entre 0 y +/- 0.29 [187]); mientras que una pequeña cantidad de valores presentan una relación moderada entre sus descriptores (i.e. valores de coeficientes entre +/-0.30 y +/-0.49 [187]). Los descriptores de tráfico que tienen una relación alta (i.e. valores de coeficientes entre +/-0.50 y +/-1 [187]) se caracterizan por ser estadísticos de tráfico calculados a partir de otros descriptores (e.g. fl, pkt, byt, pps). Es importante resaltar que, debido al comportamiento de distribución no normal de los datos (ver Tabla 4.2.8), el coeficiente de correlación más apropiado para ser calculado entre cada pareja de descriptores, es el coeficiente de Spearman [188].

Tabla 4.2.7. Sesgo de distribución de los descriptores de tráfico.

td	sp	dp	pr	tos	pkt	byt	fl	bpp	pps	bps
9.442	-0.6795	1.816	2.597	1.244	1432.598	1527.467	117.320	4.235	75.189	88.484

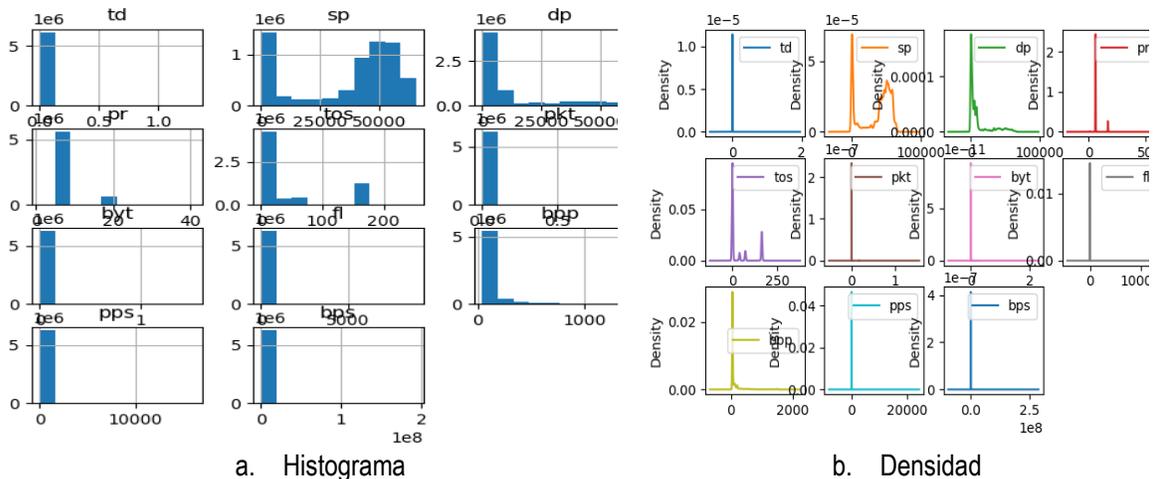
El sesgo en la distribución [189] de los descriptores tráfico (Tabla 4.2.7) representa qué tan desplazada está la curva de distribución de los datos. Para sesgo negativo (i.e. valores menores a cero), el pico de la curva de distribución se ubica a la derecha de la media; mientras que para un sesgo positivo (i.e. valores mayores a cero), el pico de la curva de distribución se ubica a la izquierda de la media. Para ambos casos, las distribuciones no tienen un comportamiento de distribución normal (i.e. valores de sesgo cero).

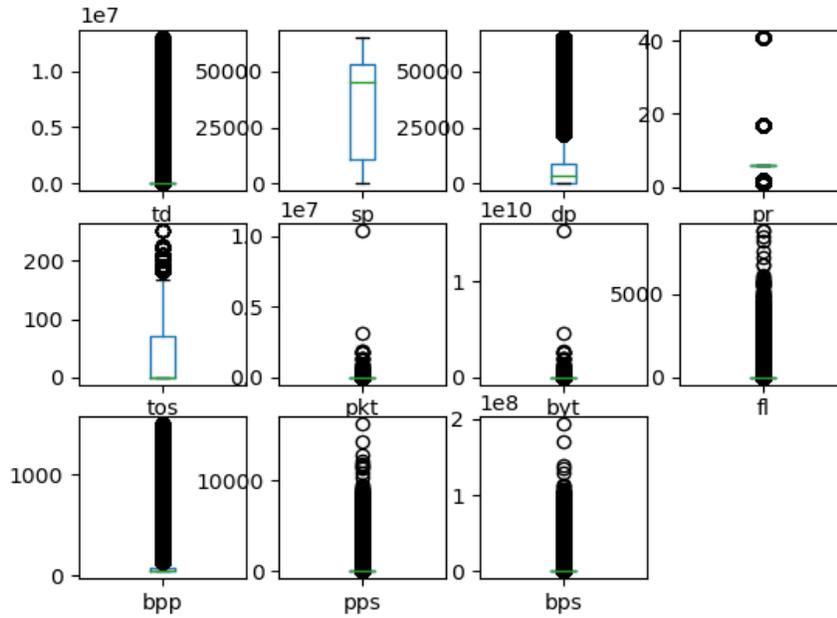
Para los datos de tráfico, el comportamiento de distribución está muy alejado de un comportamiento de distribución normal. Lo anterior se puede verificar en la Tabla 4.2.8, donde los valores de la media y mediana están muy distantes entre sí.

Tabla 4.2.8. Media y mediana de los descriptores de tráfico.

	td	sp	dp	pr	tos	pkt	byt	fl	bpp	pps	bps
media	98658.53	36163.596	10699.88	7.083	39.891	59.930	53521.697	2.889	119.026	8.593	19540.5
mediana	0.2	45159	3370	6.0	0.0	1.0	42.0	1.0	42.0	5.0	2080

Las figuras 4.2.10 y 4.2.11 presentan una exploración visual de los datos de la percepción de la calidad, separados en gráficos univariados y multivariados, respectivamente.





C. Caja y bigote

Figura 4.2.10. Gráficos univariados de descriptores tráfico.

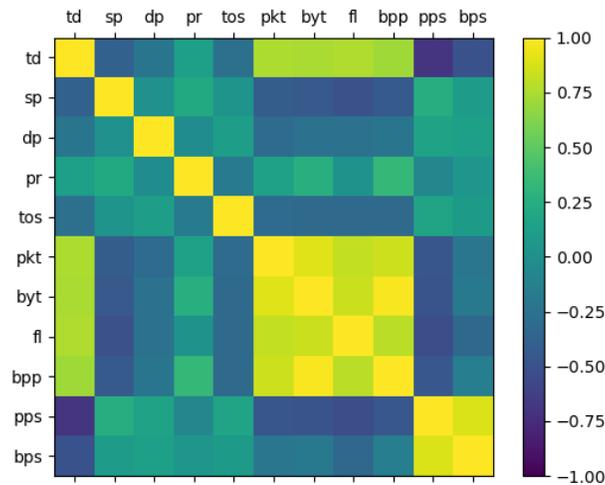


Figura 4.2.11. Matriz de Correlación (Spearman) de los descriptores de tráfico

Las figuras 4.2.10(a), 4.2.10(b), y 4.2.10(c) dan una idea visual de la distribución de los descriptores tráfico; esto es, el histograma presenta la distribución de los datos para cada descriptor, agrupando cada observación dentro de un rango o bin. El gráfico de densidad suaviza la curva dibujada por cada concentración de datos dentro del rango definido, y el gráfico de caja presenta la distribución de cada atributo o descriptor haciendo énfasis en la agrupación en cuartiles de los datos.

En este caso, el gráfico de caja indica que hay presencia de valores atípicos, los cuales superan 1.5 veces el rango intercuartílico para cada descriptor (i.e. cuartil 25% y 75%) y tienen una asimetría marcada en sus distribuciones.

La Figura 4.2.11 presenta el grado de correlación entre los descriptores de tráfico, el cual se encuentra en valores cercanos a cero, representando una baja relación entre ellos.

Finalmente, los datos de tráfico representados como flujos bidireccionales deben ser relacionados con el descriptor de la evaluación de la calidad percibida por el usuario (i.e. *qt*) con el ánimo de construir un conjunto de datos que describa el perfil paramétrico del modelo QoE.

➤ **Verificación de la calidad de datos**

Los datos recolectados en archivos planos binarios contienen datos del flujo monitorizado de acuerdo con la configuración establecida en el nodo de recolección de tráfico. En ese sentido, los elementos descriptores del flujo medidos corresponden con aquellos definidos por la herramienta nfcapd del paquete nfdump [190]. En particular, las características descritas en la Tabla 4.2.2 son aquellas que contienen datos válidos para analizar el comportamiento del tráfico. Los demás descriptores, aunque están presentes en los archivos binarios, no incluyen datos válidos para el análisis; esto se debe a que el nodo de recolección no fue configurado para procesar dichas características del flujo.

El archivo unificado con los valores totales por mes corresponde con la descripción de los flujos totales con sus respectivos descriptores válidos y sus estadísticas de tráfico respectivas (i.e. flujo, paquetes, paquetes por segundo, bits por segundo, y bytes por paquetes).

De igual manera, se ha definido un subconjunto de datos que tienen los mismos descriptores y estadísticas, pero procesados por elementos descriptores específicos que aportan al análisis del comportamiento del tráfico y establecimiento del perfil de servicio (e.g. Direcciones IP origen – destino, y tipo de servicio).

Finalmente, algunos elementos descriptores válidos presentan valores de cero, lo cual refleja que para dichos flujos no fue posible medir el elemento descriptor en dicha marca de tiempo. En consecuencia, la fase de preparación de los datos incluirá el procesamiento adecuado para corregir este error o para asignar un valor que corresponda al comportamiento específico del elemento descriptor (e.g. tos).

**B. Componente de usuario – perfil de usuario.**

La Figura 4.2.12 presenta la implementación del Componente de usuario del módulo de Recolección de datos. El bloque *QoE\_MOS* recolecta el comportamiento de consumo de servicios OTT de los usuarios en cada una de sesiones. Los datos recolectados son enviados a un servidor de correo electrónico con un formato específico para su posterior análisis (ver Anexo A).

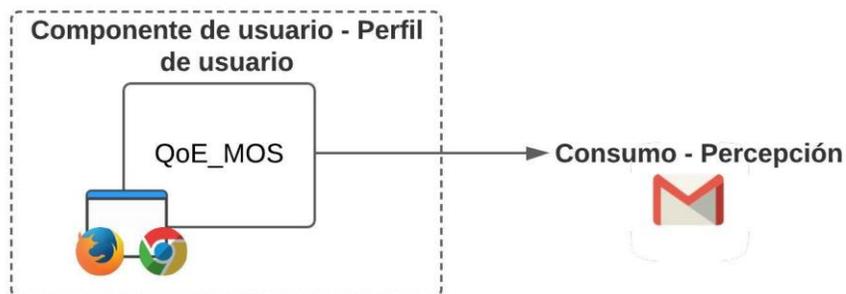


Figura 4.2.12. Componente de usuario – perfil de usuario (Módulo Recolección de datos)

## i. Comprensión del negocio

La QoE ha venido en continua evolución científica y de desarrollo en la última década (ver Capítulo 3 - Macro-componente Conceptualización); partiendo desde un punto de vista técnico como base de la experiencia que un usuario tiene sobre una aplicación o servicio, se consolidó un entendimiento de la QoE como *“la aceptabilidad general de un servicio o aplicación, tal como es percibida subjetivamente por el usuario final”* [191]. Sin embargo, esta noción definida por la ITU-T P.10/G.100 (2018) en su reporte de rectificación dos, ha sido modificada de acuerdo con los últimos consensos logrados por la comunidad científica y entidades que operan y ofertan servicios de telecomunicaciones.

En efecto, la QoE va más allá del aspecto técnico de las redes, considerando como eje central del proceso de aprovisionamiento de servicios OTT al usuario final. En ese sentido, el concepto más valorado y aceptado es el propuesto por Qualinet COST IC1003 en [10], donde define la QoE como *“el grado de deleite o disgusto de un usuario de una aplicación o un servicio. Esto resulta del cumplimiento de sus expectativas con respecto a la utilidad o disfrute de la aplicación o del servicio a la luz del estado actual y personalidad del usuario”*<sup>3</sup>

Desde un punto de vista de los servicios de telecomunicaciones (i.e. Telco), la QoE centrada en el usuario es influenciada no solo por la red, sino también por el servicio provisto (i.e. servicio OTT), el contenido del servicio, el dispositivo, y el contexto de uso de la aplicación [171]. En consecuencia, el estudio de factores que influyen la QoE en cada uno de estos niveles requiere de modelos de correlación que orienten al operador en la toma de decisiones de gestión del cliente en relación con un valor estimado de la QoE de un usuario posterior al consumo de un servicio OTT.

Por último, trabajos como [192] y [12] exponen un panorama donde las consideraciones de usuario empiezan a encontrar puntos comunes entre dos disciplinas, la QoE y UX (Experiencia de usuario). En ese sentido, abordar aspectos relacionados con el usuario final desde una perspectiva conceptual de la UX es relevante para lograr una aproximación más satisfactoria desde el dominio del operador en relación con la caracterización de la QoE de sus usuarios.

## ii. Comprensión de los datos

### ➤ Descripción de los datos

Los datos de percepción de calidad fueron obtenidos una vez el usuario realiza la evaluación de un conjunto de servicios consumidos durante su sesión de navegación (ver Figura A.3.3). La evaluación de la percepción se realiza posterior al consumo de servicios, es decir, una vez terminada la sesión de navegación, el usuario evalúa cada servicio y envía la información al nodo de recolección de datos de percepción de calidad (i.e. servicio de correo institucional). Esta estrategia de medición de la percepción de la calidad se conoce como una medición integral QoE, donde el método de evolución de tiempo corto transcurre después de terminar una sesión y asumiendo que el usuario no ha hecho uso de otro aplicativo mientras la realiza (i.e. de un segundo a varias horas) [172]

La Tabla 4.2.9 presenta la descripción general de los datos obtenidos de percepción de calidad.

<sup>3</sup> Definición de trabajo adoptada en la ITU-T P.10/G.100 (2017) [227].

Tabla 4.2.9. Descripción general de datos de percepción de calidad.

Periodo (2018/2019)	Total registros válidos	Días académicos	Días sin actividad	Días con actividad
Diciembre 10 - 21	145	10	0	10
Enero 8 - 31	51	20	1	19
Febrero 1 - 28	284	20	0	20
Marzo 1- 29	314	21	0	21
Abril 1 - 30	289	22	1	21
Mayo 1 - 31	157	23	1	22
Junio 3 -28	16	20	6	14
<b>Totales</b>	<b>1.256</b>	<b>136</b>	<b>9</b>	<b>127</b>

**Formato registro de percepción de calidad**



a0370770@lab.inf.uc3m.es

lun., 22 oct. 11:50 (ha

[('www.youtube.com', '1.0'), ('www.google.es', '1.0'), {'timeON': '10/22/18 10:49:44', 'timeOFF': '10/22/18 10:50:06'}]

Los campos de la Tabla 4.2.9 deben ser entendidos de la siguiente manera:

- Periodo: espacio temporal donde fueron generados y recolectados los datos.
- Total registros válidos: datos que representan la cantidad de registros válidos recolectados por cada mes dentro del periodo.
- Días académicos: número de días de calendario académico activo.
- Días sin actividad: número de días de inactividad de la población en las salas de prueba durante el periodo académico activo (incluye días feriados).
- Días con actividad: número de días de actividad de la población en las salas de prueba durante el periodo académico activo.
- Formato registro de percepción de calidad: formato generado luego de la evaluación de la percepción de calidad por parte del usuario.

De igual manera, se presenta un resumen, a manera de estadística, de los totales por mes y el agregado final para los registros evaluados y no evaluados (ver figuras 4.2.13 a 4.2.20).



Figura 4.2.13. Totales registros mes diciembre.



Figura 4.2.14. Totales registros mes enero.



Figura 4.2.15. Totales registros mes febrero.



Figura 4.2.16. Totales registros mes marzo.



Figura 4.2.17. Totales registros mes abril.



Figura 4.2.18. Totales registros mes mayo.



Figura 4.2.19. Totales registros mes junio.



Figura 4.2.20. Total de registros

➤ **Exploración de los datos**

Los datos de la evaluación de la percepción de la calidad tienen un conjunto de elementos que describen el comportamiento y las preferencias de consumo de servicios OTT por parte de los usuarios. El comportamiento de consumo del usuario está determinado por el momento del día que el usuario consume sus servicios, la duración de sesión de consumo, y los servicios que consume. Las preferencias de los usuarios están determinadas por las prioridades asignadas de acuerdo con el consumo de los servicios por cada usuario. Finalmente, una calificación del comportamiento del consumo general y de las preferencias del usuario determina la evaluación de la percepción general de la calidad del servicio para dicha sesión de consumo, y la evaluación específica de las preferencias de consumo de cada usuario. Las tablas 4.2.10 y 4.2.11 relacionan los datos que describen los elementos de la percepción de la calidad del servicio.

**Tabla 4.2.10.** Elementos de la percepción de la calidad del servicio.

Elementos de QoE	Descriptorios
Comportamiento de consumo	$timeOn, timeOff, s_n; n = \{1, 2, 3, 4, 5\}$
Preferencias de consumo	$s_n^{(k)}; n, k = \{1, 2, 3, 4, 5\}$
Calificación	$qt, q_x; x = \{1, 2, 3, 4, 5\}$

**Tabla 4.2.11.** Descriptorios de la percepción de la calidad del servicio

<b>s1</b>	Servicio $S_n$ consumido por un usuario con prioridad 1
<b>q1</b>	Calificación del servicio $S_n$ con prioridad 1
<b>s2</b>	Servicio $S_n$ consumido por un usuario con prioridad 2
<b>q2</b>	Calificación del servicio $S_n$ con prioridad 2
<b>s3</b>	Servicio $S_n$ consumido por un usuario con prioridad 3
<b>q3</b>	Calificación del servicio $S_n$ con prioridad 3
<b>s4</b>	Servicio $S_n$ consumido por un usuario con prioridad 4
<b>q4</b>	Calificación del servicio $S_n$ con prioridad 4
<b>s5</b>	Servicio $S_n$ consumido por un usuario con prioridad 5
<b>q5</b>	Calificación del servicio $S_n$ con prioridad 5
<b>timeOn</b>	Tiempo de inicio de la sesión del usuario
<b>timeOff</b>	Tiempo de finalización de la sesión del usuario
<b>qt</b>	Calificación general de la calidad del servicio luego de la sesión de usuario.

Es importante resaltar que, si bien los descriptorios del conjunto de datos de percepción de la calidad están nombrados como s1 a s5 (i.e. servicios) y q1 a q5 (i.e. calificaciones), la denominación del descriptor solo corresponde al nombre del servicio que ocupa una posición de preferencia para el usuario y que ha sido valorado con una métrica específica de calidad de percepción (e.g. Netflix con calificación 4.0 en escala MOS y asignado como servicio de mayor prioridad), y no a la identificación del servicio dentro del universo de servicios consumidos por los usuarios. En efecto, para un conjunto de servicios OTT  $S_n; n = \{1, 2, 3, \dots, n\}$  consumidos por los usuarios en cada una de sus sesiones, cada servicio puede tener una prioridad diferente de acuerdo con el comportamiento de consumo del usuario; por ejemplo:

Un usuario A consume 5 servicios con las siguientes prioridades  $S_1^{(1)} S_3^{(2)} S_5^{(3)} S_7^{(4)} S_9^{(5)}$ , mientras que un usuario B consume 3 servicios con las siguientes prioridades  $S_3^{(1)} S_2^{(2)} S_9^{(3)}$ . Para el usuario A, el servicio con mayor prioridad es el servicio  $S_1$ ; mientras que para el usuario B, el servicio de mayor prioridad es el servicio  $S_3$  (ambos representados por el descriptor s1 del conjunto de datos). De igual manera, ambos usuarios consumen el mismo servicio  $S_9$  (e.g. Mail), pero con diferentes prioridades (i.e. prioridad 5 y 3 para los usuarios

A y B, respectivamente). Una mayor descripción de la asignación y valoración de prioridades es presentada en la sección 4.2.3.2 literal F índice i (i.e. preparación de los datos de percepción de la calidad).

Finalmente, para una comprensión más detallada de los datos de percepción de la calidad se presenta la siguiente información descriptiva (tablas 4.2.12 a 4.2.15, y figuras 4.2.21 a 4.2.24). La información descriptiva de los datos de percepción de la calidad se realiza a partir de la revisión del conjunto de datos estructurado generado luego del proceso de preparación de los datos crudos (ver sección 4.2.3.2 literal F índice i; archivo QoSpt).

**Tabla 4.2.12.** Cantidad de datos etiquetados y no etiquetados de la percepción de la calidad – Dimensión de los datos

Datos no etiquetados (i.e. No evaluados)	Datos etiquetados (i.e. Evaluados)
(1.142, 13): 1.142 sesiones de usuario no etiquetadas con un valor de $qt = 0$ más 12 descriptores o características de percepción de la calidad (e.g. s1, q1).	(114, 13): 114 sesiones de usuario etiquetadas con un valor de $qt \neq 0$ más 12 descriptores o características de percepción de la calidad (e.g. s1, q1)
Datos Totales	
(1.256, 13): 1.256 sesiones de usuario con sus 13 descriptores de la percepción de la calidad (e.g. s1, q1, qt)	

**Tabla 4.2.13.** Tipo de datos de los descriptores de percepción de la calidad.

Descriptor	Tipo de dato
s1 a s5, timeOn, timeOff	Object
q1 a q5, qt	Float64

Las tablas 4.2.14 y 4.2.15, y las figuras 4.2.21 a 4.2.24 solo relacionan aquellos datos donde es posible obtener la descripción estadística para las sesiones etiquetadas de los usuarios (i.e. datos numéricos), principalmente por ser este el subconjunto de datos de interés para determinar la mejor estrategia de preparación y el proceso de construcción de un conjunto de datos de percepción de la calidad totalmente etiquetado a partir de un mecanismo semisupervisado.

	q1	q2	q3	q4	q5	qt
count	114.000000	114.000000	114.000000	114.000000	114.000000	114.000000
mean	3.192982	2.929825	2.552632	2.324561	2.030702	3.108626
std	1.852419	1.889511	2.049572	2.021984	1.965730	1.708906
min	1.000000	0.000000	0.000000	0.000000	0.000000	1.000000
25%	1.000000	1.000000	1.000000	1.000000	0.000000	1.000000
50%	4.000000	3.000000	1.000000	1.000000	1.000000	3.583333
75%	5.000000	5.000000	5.000000	5.000000	4.000000	5.000000
max	5.000000	5.000000	5.000000	5.000000	5.000000	5.000000

**Figura 4.2.21.** Estadística descriptiva de los datos de la percepción de la calidad para sesiones etiquetadas.

En la Figura 4.2.21, la existencia de valores mínimos de 0 en las calificaciones de los servicios  $S_n$  en las prioridades 2 a 5 significa que para una sesión específica de usuario, este ha consumido una cantidad inferior de los servicios máximos permitidos (i.e. 1, 2, 3, 4); por ejemplo, un usuario A que haya consumido dos servicios durante su sesión, tendrá dentro de su registro de sesión las calificaciones q1 y q2 respectivas, y marcadas con valores de 0 las calificaciones restantes. El valor de cero no significa una valoración nula, sino que denota el no consumo de más servicios por parte del usuario (ver sección 4.2.3.2 literal F índice i, preparación de los datos – formato matricial).

	q1	q2	q3	q4	q5	qt
q1	1.000000	0.915091	0.853366	0.831593	0.780877	0.985756
q2	0.915091	1.000000	0.893060	0.844398	0.789382	0.949680
q3	0.853366	0.893060	1.000000	0.937425	0.883876	0.879393
q4	0.831593	0.844398	0.937425	1.000000	0.897461	0.848253
q5	0.780877	0.789382	0.883876	0.897461	1.000000	0.795337
qt	0.985756	0.949680	0.879393	0.848253	0.795337	1.000000

Figura 4.2.22. Correlación de Pearson de descriptores de la percepción de la calidad para sesiones etiquetadas.

Los valores de la tabla de correlación (Figura 4.2.22) indican una relación positiva entre cada uno de los descriptores de calificación de la percepción de la calidad. Valores de +1 presentan una relación positiva perfecta (i.e. valores diagonales de la tabla); valores de -1 presentan una relación negativa perfecta; mientras que valores de 0 indica que no hay relación.

En este caso, los valores expuestos presentan un alto grado de correlación entre sus descriptores (i.e. valor de los coeficientes entre +/- 0.50 y +/- 1 [187]), por lo que algoritmos como regresión lineal o logística podrían tener un bajo desempeño [193]. El alto grado de correlación del descriptor *qt* con cada uno de los descriptores *q* se debe al método matemático de cálculo definido para este descriptor, el cual relaciona las calificaciones de cada servicio priorizado en una sesión específica del usuario (ver sección 4.2.3.2 literal F índice i, modelo matemático de calificación general de la percepción de la calidad). Es importante resaltar que el método de correlación de Pearson asume una distribución normal de los datos (ver Tabla 4.2.15)

Tabla 4.2.14. Sesgo de distribución de los descriptores de la percepción de la calidad para sesiones etiquetadas.

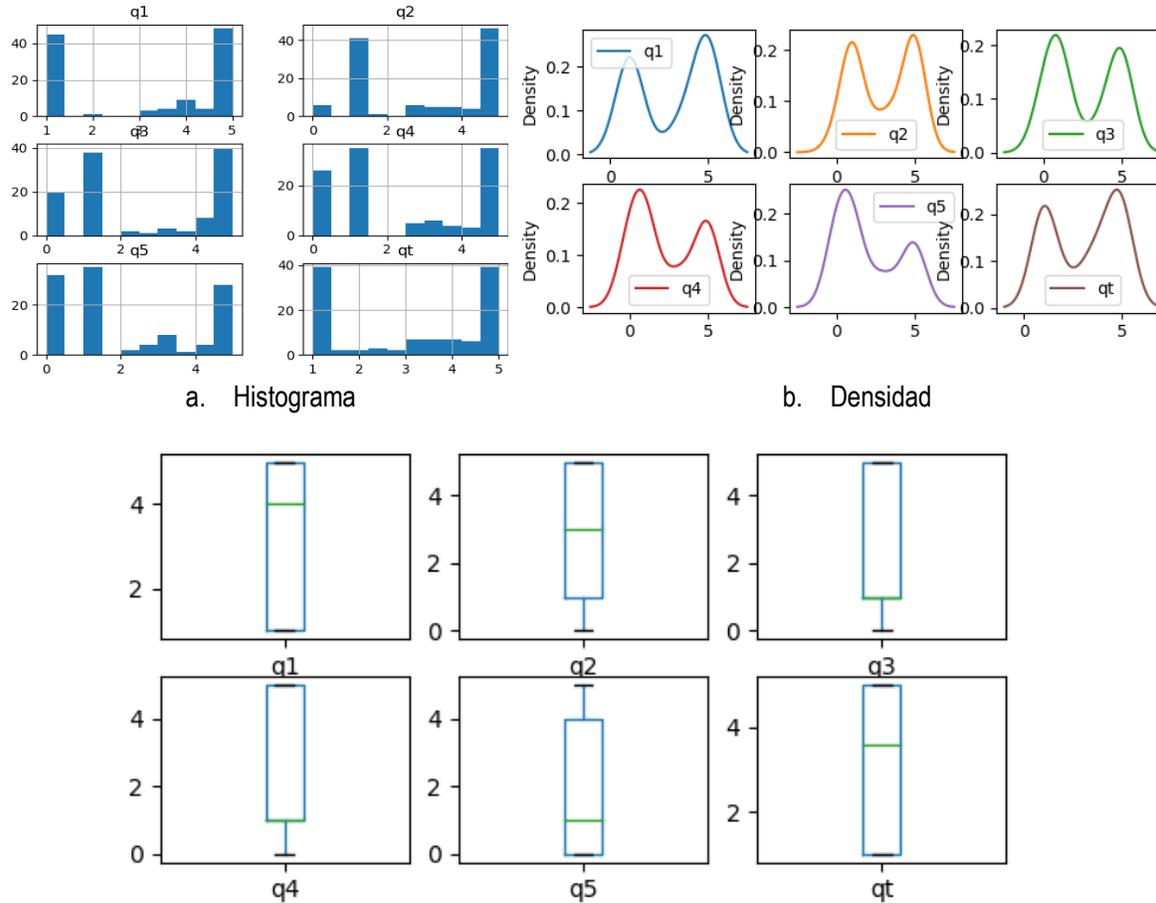
q1	q2	q3	q4	q5	qt
-0.254093	-0.073473	0.120872	0.281415	0.528785	-0.199820

El sesgo en la distribución de los descriptores de calificación de la percepción de la calidad (Tabla 4.2.14) representa qué tan desplazada está la curva de distribución de los datos. Para sesgo negativo (i.e. valores menores a cero), el pico de la curva de distribución se ubica a la derecha de la media; mientras que un sesgo positivo (i.e. valores mayores a cero), el pico de la curva de distribución se ubica a la izquierda de la media. Para ambos casos, las distribuciones no tienen un comportamiento de distribución normal (i.e. valores de sesgo cero); sin embargo, tener valores cercanos a cero permite que se pueda aplicar una transformación de distribución hacia un comportamiento más normal o gaussiano. Lo anterior también puede evidenciarse en la Tabla 4.2.15, donde los valores de la media y la mediana son cercanos entre sí; cuando los valores de la media y la mediana son muy distantes, la distribución de los datos se aleja completamente de una distribución normal [194].

Tabla 4.2.15. Media y mediana de los descriptores de la percepción de la calidad para sesiones etiquetadas.

	q1	q2	q3	q4	q5	qt
Media	3.193	2.929	2.552	2.324	2.031	3.108
Mediana	4.0	3.0	1.0	1.0	1.0	3.583

Las figuras 4.2.23 y 4.2.24 presentan una exploración visual de los datos de la percepción de la calidad, separados en gráficos univariados y multivariados, respectivamente.



C. Caja y bigote

Figura 4.2.23. Gráficos univariados de descriptores de la percepción de la calidad para sesiones etiquetadas.

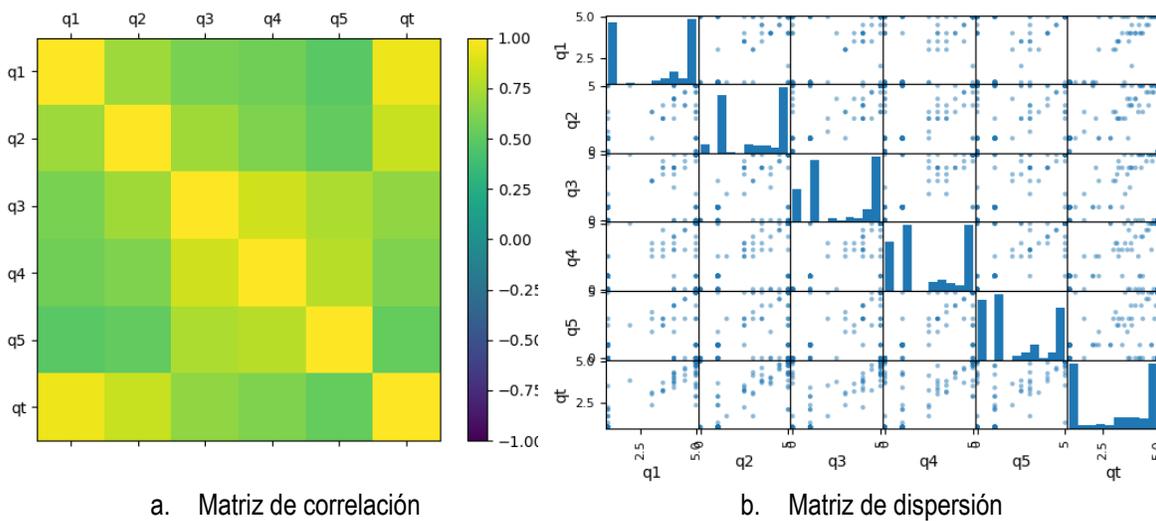


Figura 4.2.24. Gráficos multivariados de descriptores de la percepción de la calidad para sesiones etiquetadas

Las figuras 4.2.23(a), 4.2.23(b), y 4.2.23(c) dan una idea visual de la distribución de los descriptores de las calificaciones de los datos de percepción de la calidad; esto es, el histograma presenta la distribución de los datos para cada descriptor, agrupando cada observación dentro de un rango o bin. El gráfico de densidad suaviza la curva dibujada por cada concentración de datos dentro del rango definido, y el gráfico de caja presenta la distribución de cada atributo o descriptor haciendo énfasis en la agrupación en cuartiles de los datos.

En este caso, el gráfico de caja indica que no hay presencia de valores atípicos (i.e. valores más allá de los bigotes, superiores a 1.5 veces el rango intercuartílico) y que las distribuciones no son simétricas en la mayoría de descriptores (i.e. mediana no alineada en el centro del rectángulo; línea verde). De igual manera, los datos presentan dos picos en sus distribuciones, representando un comportamiento bimodal.

La Figura 4.2.24(a) presenta el grado de correlación entre los descriptores de calificación de la percepción de la calidad, y la Figura 4.2.24(b) muestra la relación entre los descriptores a través de puntos dibujados en un plano.

Para la matriz de correlación, los descriptores de calificación de la percepción se encuentran dentro del rango 0.50 a 1.00, indicando una fuerte relación entre ellos. Lo anterior se debe a que estos descriptores miden la misma variable o característica, la percepción de la calidad. Además, su correlación positiva indica que, si existe un incremento en valor de una variable, la otra tiende también a aumentar. En el caso del descriptor  $qt$ , el descriptor  $q1$  tiene un impacto más notorio en su cálculo final, por corresponder este con el servicio de mayor consumo. Por su parte, la matriz de dispersión indica gráficamente cómo están distribuidos los datos en cada emparejamiento de las variables, donde puede identificarse algún patrón; por ejemplo, una dispersión visible de los puntos entre dos pares de variables, refleja una relación nula entre estas. Por su parte, un agrupamiento de los puntos entre el par de variables, reflejaría una alta relación entre ellas, y un posible comportamiento funcional específico (e.g. comportamiento lineal si los puntos pueden ser representados con el trazo de una línea que los contenga). En este caso, es posible detectar un comportamiento cercano al lineal entre algunas de las variables de percepción (e.g.  $qt$  con  $q1$ ,  $q2$  y  $q3$ ). Finalmente, la diagonal de la matriz de dispersión representa el histograma de cada característica.

#### ➤ Verificación de la calidad de datos

Los datos de percepción de la calidad recolectados con la herramienta QoE\_MOS (Anexo A) representan el comportamiento y preferencias de consumo del usuario, los cuales determinan la evaluación de la calidad de experiencia luego de consumir servicios OTT durante una sesión específica. En ese sentido, un conjunto de descriptores de contexto del usuario fue agrupado en un archivo plano para su posterior análisis y tratamiento.

El archivo unificado de la percepción de la calidad contiene datos válidos donde se registran los servicios consumidos por los usuarios, la calificación de cada servicio en caso de haber sido realizada, el tiempo de inicio y fin de la sesión, y una bandera de notificación de evaluación o no evaluación de cada servicio. Los datos erróneos de cada una de las sesiones del usuario no fueron tenidos en cuenta en la construcción del archivo unificado (e.g. registro de una sesión de consumo sin ningún servicio reportado; nulo).

Finalmente, el cálculo del descriptor de calificación de la percepción de la calidad,  $qt$ , debe realizarse sobre un conjunto de datos debidamente estructurado; en ese sentido, el archivo plano unificado debe ser procesado para completar el formato matricial en sesiones donde los usuarios han consumido menos de la cantidad máxima habilitada de servicios (i.e. menor a cinco).

### 4.2.3.2. Módulo de Preparación de datos

La preparación de los datos es una fase dentro de la metodología CRISP-DM que permite ajustar el conjunto de datos en crudo obtenido de manera directa de las fuentes, a una estructura determinada y completamente adaptada en contenido a los requerimientos exigidos por los algoritmos de aprendizaje automático (e.g. valores con la misma escala, distribuciones normales, datos completos). En efecto, la fase de preparación de datos tiene un peso significativo dentro de la metodología CRISP-DM, principalmente por ser un proceso del que depende el correcto desempeño de la fase posterior (i.e. modelado).

Para la realización de esta fase de preparación se ha revisado un conjunto de técnicas como base conceptual del proceso, y se ha definido una estructura de preparación específica al dominio caracterizado por los datos de tráfico y de percepción de la calidad recolectados.

#### A. Tareas de preparación de datos – Visión general

Dentro de la literatura han sido definidas una gran variedad de tareas para depurar los datos antes de experimentar con algoritmos de aprendizaje automático para el desarrollo de modelos [195] [196] [197]. Muchas de estas tareas pueden ser agrupadas por tipo en algún marco de referencia que pueda ser útil al momento de seleccionar diferentes técnicas en un contexto específico y particular al dominio del problema. En ese sentido, se presenta a continuación un conjunto de tareas comunes en la fase de preparación que pueden ser aplicadas al conjunto de datos de tráfico de una red obtenido con el protocolo Netflow, y a los datos de percepción de la calidad de servicios consumidos por un usuario. La Figura 4.2.25 presenta el conjunto de tareas comunes para la preparación de los datos, las cuales son descritas a continuación.

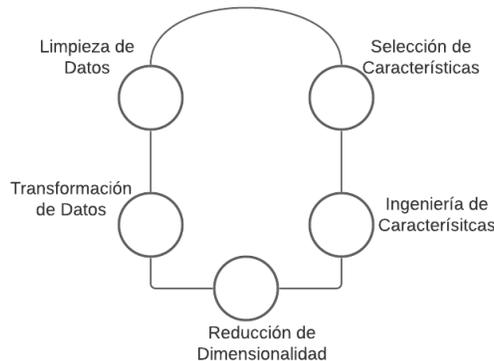


Figura 4.2.25. Tareas generales en la fase de preparación de datos

#### i. Limpieza de datos

Esta tarea de preparación de datos se enfoca en emplear técnicas para corregir errores en el conjunto de datos, filtrar datos innecesarios, depurar datos generadores de ruido, y tratar con valores perdidos [197]. La Figura 4.2.26 presenta una visión general de las técnicas de limpieza de datos más comunes.

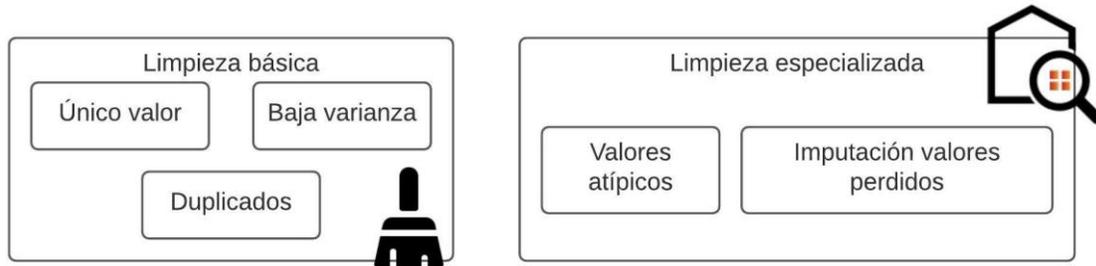


Figura 4.2.26. Visión general de técnicas de limpieza de datos  
 Construido a partir de [198]

### ii. Selección de características

Esta tarea de preparación de datos se enfoca en emplear técnicas para reducir la cantidad de atributos de un conjunto de datos, por medio de la identificación de aquellos atributos que son irrelevantes en la predicción de una variable objetivo o identificando aquellos con poca o nula relación entre ellos [197]. La Figura 4.2.27 presenta una visión general de las técnicas de selección de características más comunes.

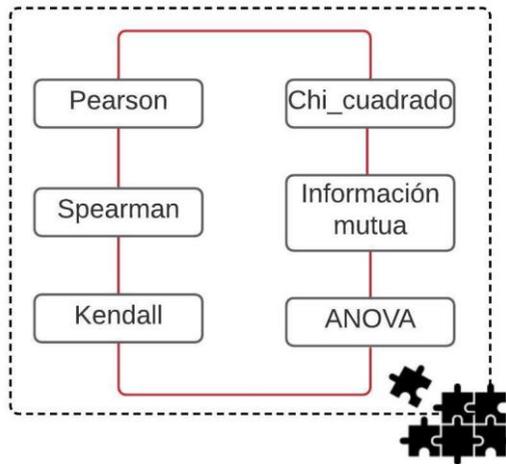
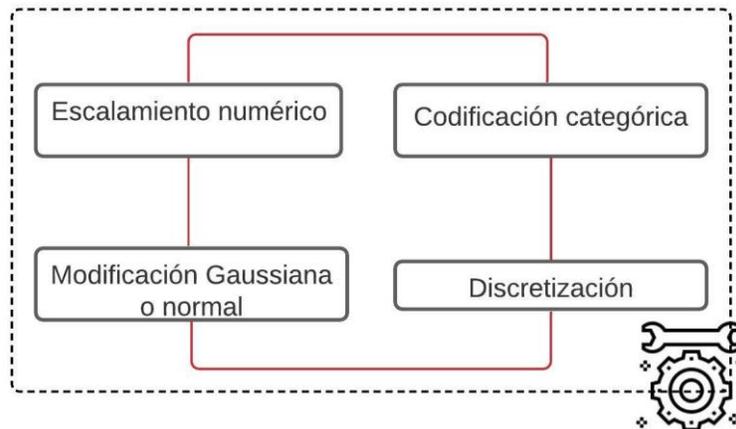


Figura 4.2.27. Visión general de técnicas de selección de características  
 Fuente: Adaptado de [198]

### iii. Transformación de datos

Esta tarea de preparación de datos se centra en emplear técnicas para modificar la estructura y comportamiento de cada atributo del conjunto de datos [197]. La Figura 4.2.28 presenta una visión general de las técnicas de transformación de datos más comunes.



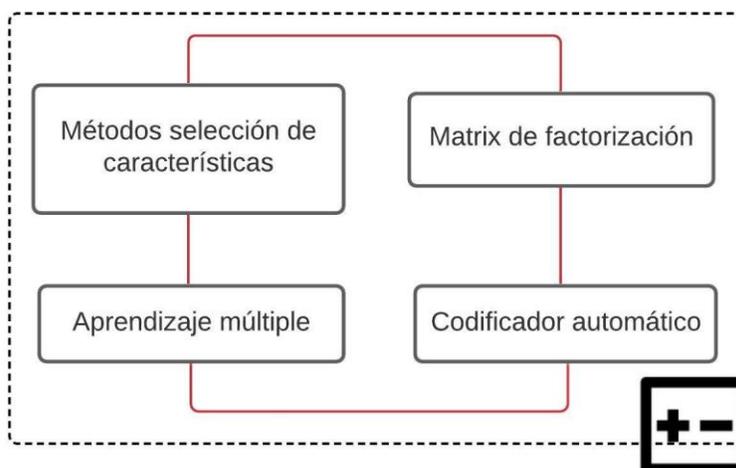
**Figura 4.2.28.** Visión general de técnicas transformación datos  
 Construido a partir de [198]

#### iv. Ingeniería de características

Esta tarea de preparación de datos se enfoca en emplear técnicas para crear nuevos atributos a partir de los existentes en el conjunto de datos [198]. Una de las técnicas más empleadas es la transformación polinomial, la cual genera copias de variables numéricas con valores modificados a partir de una potencia  $n$  [198].

#### v. Reducción de dimensionalidad

Esta tarea de preparación de datos se enfoca en emplear técnicas para reducir el número de atributos o instancias disponible en un conjunto de datos [197]. La Figura 4.2.29 presenta una visión general de las técnicas de reducción de dimensionalidad más comunes.



**Figura 4.2.29.** Visión general de técnicas de reducción de dimensionalidad  
 Construido a partir de [198]

### B. Proceso de preparación de datos en contexto

La definición de una estructura de tareas de preparación de datos en contexto consiste en la definición de un flujo de acciones encaminadas a obtener un conjunto de datos específico del dominio del problema que se

acople a los requerimientos de diferentes algoritmos de aprendizaje en su fase de modelado. Para ello, a continuación se describen aquellas tareas de preparación de datos que pueden ser aplicadas de acuerdo con el resultado de la fase de comprensión de datos, y posteriormente, se define una estructura de preparación de datos específica para los datos recolectados de tráfico y de percepción de la calidad.

La Figura 4.2.30 ilustra un marco general para la aplicación de tareas de preparación de datos de acuerdo al contexto de aplicación.

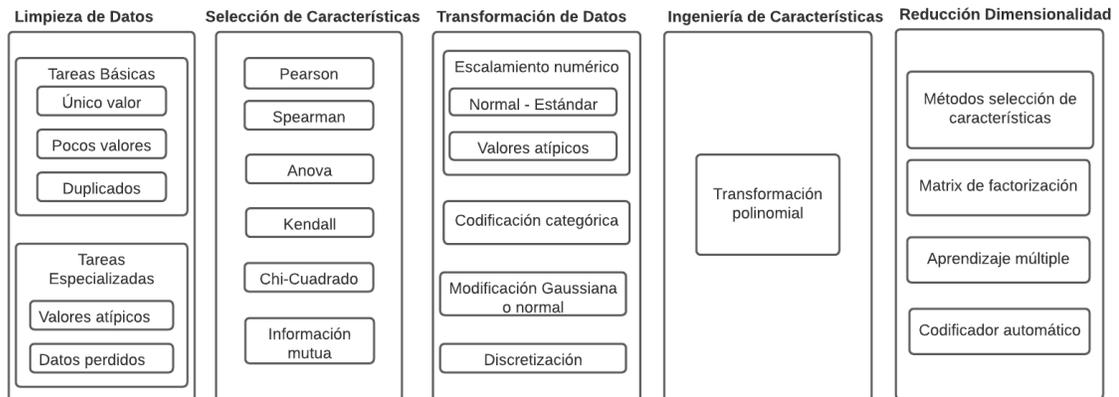


Figura 4.2.30. Marco general de tareas de preparación de datos en contexto. Construido a partir de [198]

### i. Limpieza de datos – tareas básicas

Para realizar una limpieza inicial de los datos, las tareas de único valor, pocos valores, y duplicados, analizan la variables o atributos de los datos de red o de usuario que menor utilidad tengan para la fase de modelamiento; esto es:

- Valor único: Representa variables o atributos con único valor que no aportan información para la fase de modelado, principalmente por ser un predictor con varianza cero.
- Pocos valores: Representa variables o atributos con una cantidad menor de valores que podrían ser considerados como predictores de valor cercano a una varianza-cero. En ese sentido, estos atributos podrían ser eliminados de acuerdo con algún criterio específico (e.g. baja varianza).
- Duplicados: Representa observaciones redundantes dentro del conjunto de datos que no son útiles en la fase de modelado y por tanto deben ser eliminadas.

### ii. Limpieza de datos – tareas especializadas

Estas tareas están orientadas a depurar los datos de acuerdo con la identificación de valores perdidos y atípicos que puedan estar presentes en el conjunto de datos de tráfico.

#### ➤ Identificación de valores atípicos

Esta tarea de limpieza de datos consiste en la identificación de valores extremos que están por fuera del rango esperado o más probable de los datos [197]. Estos valores atípicos pueden ser observaciones poco probables, errores en las medidas o datos dañados. En ese sentido, es importante conocer el dominio del problema con el objeto de decidir si el dato es verdaderamente un valor atípico. Técnicas como desviación estándar y rango intercuartil son usadas para corregir la presencia de estos valores.

- Desviación estándar: Técnica por la cual los valores atípicos son identificados y luego removidos a partir de la definición de un porcentaje de los datos (e.g. 1 desviación estándar equivale a un 68% de los datos [198]). Sin embargo, esta aproximación requiere que la muestra tenga un comportamiento gaussiano completo o similar.
- Rango intercuartil (IQR): Técnica que calcula la diferencia ponderada entre los cuartiles 75 y 25 de los datos con el ánimo de identificar los valores atípicos (e.g. datos a 1,5 veces el IQR [198]). Adicionalmente, esta técnica no requiere que los datos tengan una distribución gaussiana.

Aunque las técnicas anteriores son aplicadas generalmente a datos univariados, estas se pueden extender a un espacio multivariable con procedimientos más complejos. No obstante, existe la técnica de Valor Atípico Local (LOF, *Local Outlier Factor*) que se apoya en el concepto de vecinos más cercanos para la detección de valores atípicos en espacios multidimensionales [198]. En consecuencia, resulta conveniente su aplicación en el conjunto de datos de tráfico debido a su estructura, comportamiento, y tipo de dato de cada atributo (e.g. atributos con comportamiento sesgado y con escalas diferentes).

### ➤ Identificación de datos perdidos

Para la identificación de datos perdidos, los cuales representan valores de atributos que no fueron monitorizados para un flujo de tráfico específico en un tiempo determinado, o valores de calificaciones en servicios nulos o no reconocidos, debe realizarse una inspección por cada atributo de la cantidad de valores que están ausentes. Para ello, se pueden abordar tres aproximaciones. La primera, imputación estadística; la segunda, imputación KNN; y la tercera, imputación iterativa.

#### Imputación estadística

Para esta aproximación, el reemplazo de los valores perdidos se realiza a partir del cálculo de una estadística del atributo [198]; es decir, los datos marcados con nan (i.e. *Not a Number*) para los valores no presentes son reemplazados por un valor estadístico del atributo que lo contiene. Estos valores estadísticos pueden ser: la media, la mediana, el valor más frecuente, y un valor constante.

#### Imputación vecino más cercano – KNN

Para esta aproximación, el reemplazo de los valores perdidos en cada atributo se realiza haciendo uso del algoritmo KNN [198]; es decir, los datos marcados con nan (i.e. *Not a Number*) para valores no presentes son reemplazados por un valor obtenido por la predicción del modelo de imputación KNN para cada atributo.

#### Imputación iterativa

Para esta aproximación, el reemplazo de los valores perdidos en cada atributo se realiza haciendo uso de un modelo por cada atributo en función de los atributos restantes [198]; es decir, los datos marcados con nan (i.e. *Not a Number*) para valores no presentes son reemplazados por un valor obtenido de la predicción del modelo que representa cada atributo en función de los otros atributos.

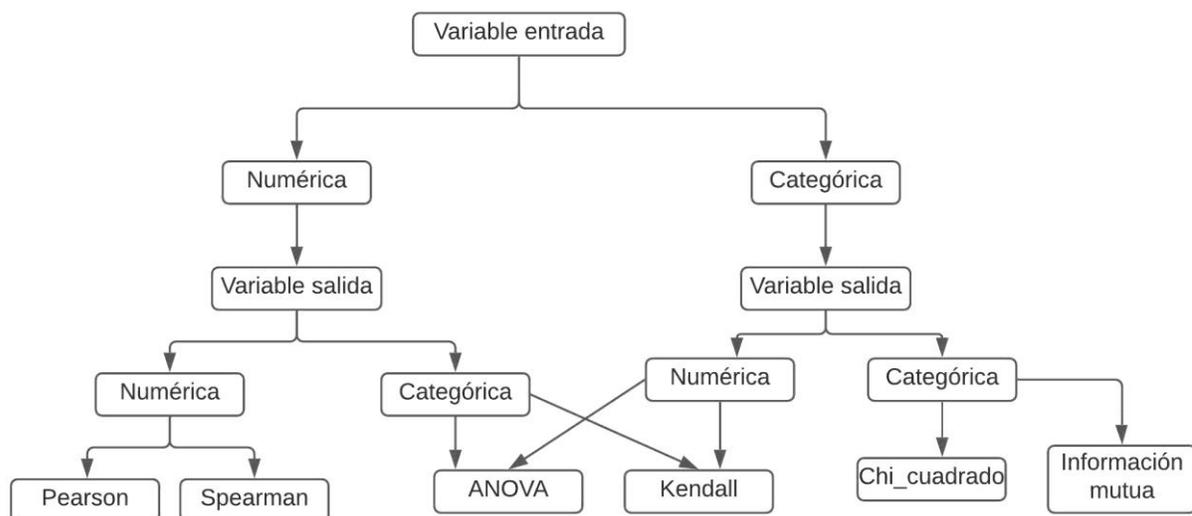
### iii. Selección de características

Esta tarea está enfocada en la reducción del número de variables de entrada cuando se desarrollan modelos predictivos [198]. Para ello, diferentes técnicas evalúan la relación entre cada una de las variables en función de la variable objetivo a predecir o la utilidad de estas en el modelo evaluado. En consecuencia, las técnicas se pueden diferenciar en dos aproximaciones. La primera, una estrategia no supervisada donde no se usa una variable objetivo, centrándose en remover los atributos redundantes por medio de la correlación existente o

evaluando la poca varianza de cada uno de ellos (i.e. limpieza de datos por pocos valores con criterio de varianza); la segunda, una estrategia supervisada donde se usa una variable objetivo, centrándose en remover variables irrelevantes. En esta última, se destacan tres grupos [198]:

- Intrínseco: Algoritmos que desempeñan automáticamente la selección de características durante el entrenamiento.
- Filtro: Selecciona un subconjunto de características a partir de la relación con el objetivo.
- Envoltura: Busca un subconjunto de características con mejor desempeño de acuerdo con el modelo predictivo.

Adicionalmente, en [198] se ha definido un esquema de aplicación de técnicas de selección de características (ver Figura 4.2.31)



**Figura 4.2.31.** Esquema de técnicas para la selección de características  
**Fuente:** Adaptado de [198]

#### iv. Transformación de datos

La Figura 4.2.32 presenta un resumen de las tareas más usadas para realizar la transformación de los datos, y las cuales son candidatas para su aplicación sobre el conjunto de datos de tráfico y de percepción de calidad de servicio.

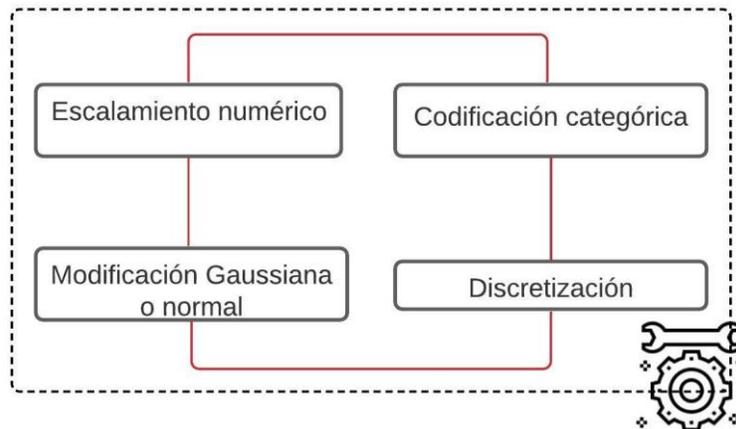


Figura 4.2.32. Tareas de transformación de datos  
 Construido a partir de [198]

➤ **Escalamiento numérico.**

Dentro de las técnicas más empleadas para escalar datos numéricos, se encuentran las tareas de normalización y estandarización. La primera, escala cada entrada o atributo de manera separada a un rango entre 0 y 1, donde los valores en formato flotante permiten tener un mayor grado de precisión [198] (ver ecuación 6). La segunda, escala cada entrada o atributo de manera separada haciendo uso de la media, la cual es dividida por la desviación estándar con el objeto de cambiar la distribución de los datos con una media de cero y una desviación estándar de uno [198] (i.e. centrar los datos; ver ecuación 7).

$$y = \frac{x - \min}{\max - \min}, \text{ donde } y \text{ es el valor escalado; } x \text{ el valor a escalar (6)}$$

$$y = \frac{x - \text{mean}}{\text{desviación estándar}}, \text{ donde } y \text{ es el valor escalado; } x \text{ el valor a escalar (7)}$$

Fuente: Tomado de [198]

En el caso del conjunto de datos de tráfico, los atributos numéricos difieren tanto en unidades como en tamaño de las escalas; en consecuencia, esto podría aumentar la dificultad de obtener el modelo respectivo que aprende de valores muy dispersos donde los algoritmos empleados se ven afectados por la ponderación de sus valores de entrada (e.g. regresión lineal, regresión logística, redes neuronales). Además, estos modelos resultan inestables y con mucha sensibilidad a valores de entrada que propician una alta generalización del error.

Para los datos de percepción de la calidad, los descriptores numéricos que representan las calificaciones de los servicios (e.g. q1, q2), al tener un comportamiento cercano al normal, la transformación por estandarización y posteriormente la normalización de los datos sería una opción adecuada para su tratamiento.

**Escalamiento de datos numéricos con valores atípicos**

Teniendo en cuenta que muchos algoritmos de aprendizaje automático se desempeñan mejor con variables numéricas de entrada con escalas en un rango estándar, la técnica de estandarización con presencia de valores atípicos puede llegar a estar sesgada [198]. En consecuencia, es necesario un escalamiento más robusto,

donde la mediana y los rangos intercuartiles pueden ser usados para optimizar la técnica de escalamiento por estandarización.

En el caso del conjunto de datos de tráfico, los atributos o descriptores del flujo difieren tanto en unidades de medida como en su rango de valores; en consecuencia, aquellos descriptores que presenten valores grandes podrían dominar o sesgar algunos algoritmos de aprendizaje (e.g. el atributo bps, bits por segundo, prevalecería sobre el atributo td, tiempo de duración, al momento del entrenamiento del modelo); mientras que, para los datos de percepción de la calidad, la no presencia de valores atípicos no requiere el empleo de esta técnica.

Para esta técnica de estandarización, el escalamiento robusto permite ignorar los valores atípicos del cálculo de la media y de la desviación estándar, y posteriormente obtener el valor escalado a partir rango intercuartil (IQR,  $p_{75} - p_{25}$ ; ver ecuación 8). Es importante resaltar que los valores atípicos se mantienen dentro del conjunto de datos, pero no son tenidos en cuenta para el procedimiento de escalado.

$$y = \frac{x - \text{mediana}}{p_{75} - p_{25}}, \text{ donde } y \text{ es el valor escalado; } x \text{ el valor a escalar (8)}$$

Fuente: tomado de [198]

### ➤ Codificación de datos categóricos

Para variables con valores categóricos donde se requiere de una codificación interna para su procesamiento por parte de los algoritmos de aprendizaje automático, las técnicas empleadas más comunes son la codificación ordinal, la *one-hot*, y de variable ficticia; esto es:

- Codificación ordinal: a cada único valor de categoría le es asignado un valor entero. Sin embargo, esta codificación puede imponerle a la variable categórica una relación ordinal que normalmente no tiene (e.g. tos, tipo de servicio).
- *One-hot*: para cada valor de categoría se codifica un valor binario donde su marca en uno representa la existencia del valor de la categoría (e.g. s1). Sin embargo, esta codificación introduce redundancia en la variable transformada.
- Variable ficticia: para cada valor de categoría se codifica un valor binario donde su marca en uno representa la existencia del valor de la categoría, a excepción de una categoría seleccionada como base, donde la marca de uno no está presente (e.g. s1). En consecuencia, el valor binario codificado tiene la cantidad de  $n - 1$  bits ( $n$ : número de categorías).

Para los datos de tráfico, una primera revisión de los datos completos por flujo (i.e. flujos unidireccionales) presenta un descriptor categórico que requiere su transformación (i.e. pr, protocolo de conexión IP); sin embargo, esta transformación puede ser empleada en la etapa inicial de lectura del archivo binario con una configuración específica que determine el valor numérico del descriptor de acuerdo con su categoría asignada (e.g. TCP asignado con valor 1); mientras que, para los datos de la percepción de la calidad, los descriptores que representan los servicios deben ser transformados con una estrategia *One-hot* o de variable ficticia (e.g. s1, s2).

### ➤ Modificación gaussiana o normal

Algunos algoritmos de aprendizaje automático asumen que las variables numéricas tienen una distribución o comportamiento gaussiano; sin embargo, el conjunto de datos puede no reunir este requerimiento, teniendo para cada variable una distribución cercana a una distribución gaussiana (e.g. distribución afectada por valores atípicos o con un sesgo determinado) o una distribución completamente diferente (e.g. distribución

exponencial). En ese sentido, técnicas como la transformada de Box-Cox o de Yeo-Johnson permiten realizar un cambio en el comportamiento de las variables de los datos hacia una distribución más gaussiana.

### Transformada de potencia

Este tipo de transformada permite que la distribución de una variable tenga un comportamiento más gaussiano con el fin de ajustarse a los requerimientos de algunos algoritmos de aprendizaje automático (e.g. regresión lineal o de regresión logística) o que sean objeto de un mejor desempeño para aquellos algoritmos que no asumen este comportamiento en sus variables de entrada. En efecto, las transformadas de potencia estabilizan la varianza en la distribución de las variables del conjunto de datos.

Para este tipo de transformadas, el hiperparámetro lambda puede ser encontrado de tal manera que la mejor transformada pueda ser aplicada a la variable con el ánimo de tener un comportamiento más gaussiano; esto es (ver Tabla 4.2.16):

**Tabla 4.2.16.** Valores lambda para diferentes transformada de potencia  
 Fuente: Tomado de [198]

Valor	Descripción
-1.0	Transformación recíproca
-0.5	Transformación raíz cuadrada recíproca
0.0	Transformación logarítmica
0.5	Transformación raíz cuadra
1.0	No hay transformación

- Transformada Box-Cox: transformada de potencia que asume que todos los valores de los atributos son positivos; es decir, que valores de cero y negativos no son soportados [197]. Es recomendable escalar los datos antes de proceder con este tipo de transformación (e.g. normalización con rango de 1-2).
- Transformada Yeo-Johnson: transformada de potencia que no requiere que los valores de los atributos sean positivos [198]. Es recomendable estandarizar los datos antes de proceder con este tipo de transformación (e.g. estandarización).

Para el conjunto de datos de tráfico, estas técnicas son de gran ayuda teniendo en cuenta la distribución sesgada de los datos de cada atributo. De igual manera, para los datos de percepción de la calidad, estas técnicas pueden ajustar el comportamiento de los datos a una distribución más normal.

### Cambio de distribución en los datos numéricos

En ocasiones, las variables o atributos del conjunto de datos tienen una distribución altamente sesgada o no estándar, principalmente por la presencia de valores atípicos; incluso, su distribución puede tener comportamiento multimodal o exponencial. En consecuencia, algunos algoritmos de aprendizaje se pueden ver altamente afectados. Sin embargo, la transformada de cuantiles permite transformar la distribución altamente sesgada o no estándar de los datos de una variable numérica en una distribución de probabilidad diferente que pueda ser empleada de manera efectiva en la etapa de modelado (e.g. distribución normal o uniforme).

- Transformación cuantil o de punto porcentual: transforma la distribución de probabilidad de una variable a otra distribución de probabilidad [198]. La función de punto porcentual (PPF, *percent-point function*) regresa el valor en una probabilidad dada o por debajo de ella.

Las opciones para la transformación de cuantiles se centran en las transformaciones normal y uniforme [198]. La primera, cuando se requiere que los datos transformados tengan un comportamiento estrictamente gaussiano para que se ajusten mejor a un algoritmo en particular; la segunda, cuando se tiene presencia de valores atípicos que son más comunes que raros, afectando la distribución inicial de los datos de la variable con valores grandes y dispersos (e.g. multimodal o exponencial).

Para el conjunto de datos de tráfico, esta técnica probablemente es la más adecuada debido al comportamiento específico de cada atributo, donde la distribución de los datos es altamente sesgada y muy alejada de una distribución normal; mientras que para los datos de la percepción de la calidad, el comportamiento es cercano a una distribución normal que solo es afectado mínimamente por la presencia de un sesgo (ver sección 4.2.3.1 literal A índice ii, comprensión de los datos).

### ➤ Discretización

Esta técnica de transformación de datos consiste en cambiar la distribución de los datos de cada variable numérica por una distribución diferente con base en categorías discretas [197]. En efecto, algunos algoritmos de aprendizaje automático se adaptan mejor con variables de entrada de tipo categórico u ordinal y con distribuciones estándar (e.g. árboles de decisión y basado en reglas).

Los valores de la variable numérica son agrupados en contenedores discretos donde a cada contenedor o bin le es asignado un único valor entero de manera que sea conservada la relación ordinal entre los bins. Entre las estrategias más comunes para el agrupamiento de los valores de la variable se pueden resaltar [198] :

- Uniforme: cada grupo o bin tiene el mismo ancho en el intervalo de valores posibles de la variable. Adicionalmente, la distribución de probabilidad de cada variable se mantiene.
- Cuantil: cada grupo o bin tienen el mismo número de valores de acuerdo con los percentiles.
- Clúster: cada valor es asignado a un clúster previamente definido.

El número de contenedores se debe definir dependiendo de la estrategia seleccionada. Para el caso uniforme, el número de bins es flexible; para la estrategia de cuantil, el número de bins debe ser menor que el número de observaciones o percentiles de la variable (e.g. 10); finalmente, en la estrategia clúster, el número de bins deber ser un número razonable que pueda ser encontrado para esa variable (e.g. 3 – 5 clústers [198]). Adicionalmente, es necesario definir el tipo de codificación a utilizar para cada uno de los bins conformados (e.g. ordinal o *One-hot*).

Para los dos conjuntos de datos, de tráfico y de percepción de la calidad, esta aproximación no es la más apropiada de acuerdo con la finalidad del modelo de correlación, donde se requiere conocer cada sesión para validar y comparar la evaluación de la calidad de la experiencia de sus usuarios; sin embargo, esta técnica podría emplearse para el agrupamiento de un conjunto de usuarios y de servicios con comportamientos similares con el ánimo de generar planes de aprovisionamiento de servicios OTT específicos.

### v. Ingeniería de características

Esta tarea se enfoca en generar nuevas variables a partir de las ya existentes [198]. Para ello, la técnica polinomial transforma el conjunto de datos desde una cantidad  $n$  de atributos a una cantidad  $n + p$ , donde  $p$  es un número calculado a partir del grado de un polinomio usado en la conversión de los valores de los atributos iniciales [198]. Sin embargo, esta aproximación incrementa sustancialmente el número de características del conjunto de datos, ocasionando un sobreajuste del modelo con resultados incorrectos.

Teniendo en cuenta el conjunto de datos de tráfico, esta aproximación no es óptima, principalmente por la cantidad de características implícitas en el protocolo Netflow que dan cuenta del comportamiento de tráfico en el nodo de recolección. Por otra parte, este proceso de ingeniería de características ya es ejecutado en una fase inicial donde los datos son recolectados; esto es: la generación de estadísticos propios del sistema Nfdump a partir de los datos binarios entregados por el nodo recolector (e.g. bps, pps); mientras que, para los datos de percepción de la calidad, solo el valor de la evaluación de la percepción ha sido generado a través de un modelo matemático (i.e. descriptor *qt*).

**vi. Reducción de la dimensionalidad**

Esta tarea de preparación de datos consiste en reducir la cantidad de atributos del conjunto de datos. Para ello, técnicas como selección de características (e.g. RFE, *Recursive, Feature Elimination*), matriz de factorización (e.g. PCA, *Principal Components Analysis*), aprendizaje múltiple (e.g. SOM, *Kohonen Self-Organizing Map*) y codificador automático son algunas de las estrategias más usadas para completar esta tarea [198].

Para aplicar cualquiera de las técnicas de reducción de dimensionalidad es recomendable escalar los valores de las variables de entrada con el objeto de lograr un mejor desempeño de la técnica seleccionada. En consecuencia, cada descriptor o atributo del conjunto de datos de tráfico o de percepción de la calidad debe ser escalado antes de proceder con alguna de estas técnicas en caso de requerir su ejecución. Sin embargo, los descriptores de tráfico monitorizados por el nodo recolector no corresponden a la totalidad de los elementos descriptores del protocolo Netflow, por lo que la dimensión del conjunto de datos no es significativa. De igual manera, esta técnica de preparación no es relevante para el conjunto de datos de la percepción de la calidad.

**C. Resumen de técnicas de preparación de datos aplicables al conjunto de datos.**

La Tabla 4.2.17 presenta un resumen del grado de aplicación de la técnica de preparación de datos para cada uno de los conjuntos de datos del modelo.

**Tabla 4.2.17.** Grado de aplicación de las tareas del marco general de preparación de datos

<b>Conjunto de datos de tráfico</b>	
<b>Tareas de preparación</b>	<b>Grado de aplicación</b>
Limpieza de datos	Alta
Selección de las características	Medio
Transformación de datos	Alta
Ingeniería de características	Bajo
Reducción de dimensionalidad	Bajo
<b>Conjunto de datos de percepción de la calidad</b>	
<b>Tareas de preparación</b>	<b>Grado de aplicación</b>
Limpieza de datos	Media
Selección de las características	Baja
Transformación de datos	Alta
Ingeniería de características	Bajo
Reducción de dimensionalidad	Bajo

- Alto grado de aplicación: Técnica que debe ser aplicada en el conjunto de datos de acuerdo con el comportamiento visto en la comprensión de los datos.
- Medio grado de aplicación: Técnica que puede ser aplicada en el conjunto de datos en combinación con otras con el ánimo de mejorar la estructura final de los datos.
- Bajo grado de aplicación: Técnica que no requiere ser aplicada en el conjunto de datos de acuerdo con el comportamiento visto en la comprensión de los datos.

A continuación, se presenta un reporte de la ejecución de las tareas de preparación de datos para cada conjunto de datos del modelo, teniendo en cuenta las tareas conceptuales de CRISP-DM y el marco general definido (ver Tabla 4.2.18).

**Tabla 4.2.18.** Correspondencia de las tareas de preparación de datos.

<b>Tareas conceptuales CRISP-DM para preparación de datos [60]</b>	<b>Tareas del marco general para la preparación de datos</b>
Selección de datos	Selección de características. Reducción de dimensionalidad
Limpieza de datos	Limpieza de datos
Construcción de nuevos datos	Ingeniería de características
Integración de datos	-
Formateo de datos	Transformación de datos

#### **D. Reporte de preparación de datos de la percepción de la calidad**

##### **i. Selección de datos**

La selección de datos implica seleccionar aquellos elementos (i.e. filas) y características (i.e. columnas) que son relevantes para el cumplimiento de los objetivos de minería [60]. En ese sentido, para el conjunto de datos de percepción de la calidad, las características seleccionadas incluyen todas aquellas recolectadas en la monitorización de la sesión del usuario (i.e. servicios, tiempo de sesión, y calificaciones). Si bien el reporte del grado de correlación es alto entre los descriptores de calificación (i.e. correlación de Pearson), estas características deben mantenerse dentro del conjunto de datos debido a su importancia para el cálculo de la evaluación total de la calidad percibida del usuario.

En relación con las técnicas de reducción de dimensionalidad, no se hace necesaria su aplicación debido a los pocos descriptores del comportamiento de consumo y percepción de la calidad del servicio por parte del usuario (i.e. servicio y percepción).

##### **ii. Limpieza de datos**

La limpieza de los datos implica analizar problemas en los datos seleccionados con el ánimo de purificarlos o solucionarlos [60]. En ese sentido, las técnicas de limpieza de los datos empleadas fueron ejecutadas en la etapa inicial del proceso de lectura y conversión de los datos; esto es:

- Detección de registros no válidos correspondientes a servicios nulos en sesiones activas de los usuarios.
- Eliminación de registros no válidos antes de construir un conjunto de datos que integre todas las sesiones de los usuarios para el periodo de monitorización.
- Eliminación de caracteres especiales en el formato de los datos recolectados.
- Completar el formato matricial para su análisis.

##### **iii. Construcción de nuevos datos**

La construcción de nuevos datos implica crear una nueva característica (i.e. derivación de atributos) o generar nuevos registros (i.e. filas) con el ánimo de aportar más información al conjunto de datos [60]. En ese sentido, para el conjunto de percepción de la calidad no se ha seguido una técnica específica en la tarea de ingeniería de características, pero sí se han generado descriptores que amplían el contexto del usuario; esto es:

- Generación de un atributo de evaluación total,  $qt$ , a partir de un modelo matemático definido (i.e. modelo matemático de cálculo de la evaluación final para una sesión de usuario).
- Generación de un atributo de duración de la sesión de consumo de servicios por parte del usuario, a partir de los descriptores de inicio y fin de la sesión.
- Generación de atributos de contexto del momento de día donde la sesión está activa, a partir de los descriptores de inicio y fin de la sesión.

#### iv. Integración de datos

La integración de los datos implica una unificación de varios datos en un solo conjunto que responda al objetivo de análisis definido [60]. En ese sentido, para el conjunto de datos de la percepción de la calidad, la adición de datos fue empleada para cada conjunto de datos que representan las sesiones de los usuarios. La adición de datos consiste en integrar conjuntos de datos con atributos similares, pero con registros distintos [60].

#### v. Formateo de datos

El formateo de los datos implica adecuar la estructura de los datos para satisfacer los requerimientos de los algoritmos en la fase de modelado [60]. En ese sentido, se aplicaron técnicas de transformación de datos al conjunto de datos de la percepción de la calidad; esto es:

- Codificación categórica a través de la transformación *One-hot* para descriptores de tipo categórico (i.e. servicios).
- Completitud matricial a través de la codificación de servicio para sesiones con un número inferior de servicios permitidos. Esta codificación denota que el usuario ha consumido menos servicios de los máximos monitorizados por sesión.
- Modificación gaussiana normal a través de la transformación de potencia Yeo-Johnson. Esto debido a la distribución de los datos cercana a una distribución normal.
- Escalamiento numérico por normalización.

### E. Reporte de preparación de datos de tráfico

#### i. Selección de datos

Para el conjunto de datos de tráfico, las características seleccionadas incluyen todas aquellas recolectadas por el protocolo Netflow. Si bien el reporte de correlación de Spearman presenta alto grado de relación entre algunas parejas de descriptores (e.g. fl, bpp, bps), la totalidad de las características son conservadas con el ánimo de predecir la percepción de la calidad. De igual manera, la selección de los datos también implica una selección de los registros que se emplearán para el cumplimiento del objetivo definido [60]. En consecuencia, los registros seleccionados para conformar el conjunto de datos que entrenará el modelo de la predicción de la percepción de la calidad son aquellos que han sido ponderados con un valor de  $qt$  diferente de cero. La Tabla 4.2.19 presenta el resumen de la dimensión de los datos seleccionados para el análisis.

**Tabla 4.2.19.** Dimensión de los datos de tráfico para los perfiles de servicio y paramétrico

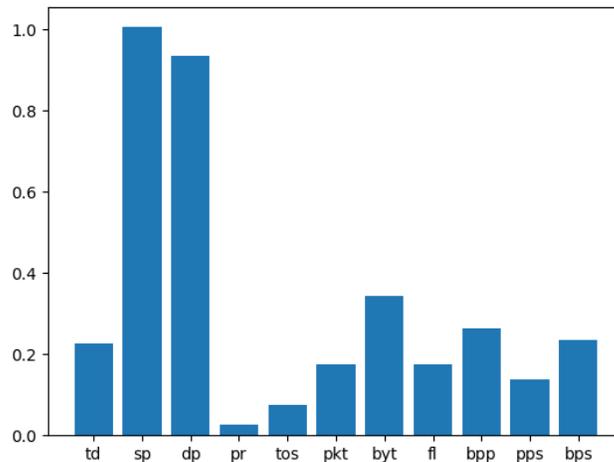
Flujos individuales (perfil de servicio)	Flujos bidireccionales (perfil de servicio)	Flujos bidireccionales etiquetados (perfil paramétrico)
(18.052.583, 17): 18.052.583 flujos individuales con 17 descriptores válidos (Tabla 4.2.6)	(6.247.144, 17): 6.247.144 flujos bidireccionales con 17 descriptores válidos (Tabla 4.2.6)	(1.410.563, 16): 1.410.563 flujos bidireccionales con 15 descriptores válidos más el atributo $qt$ con valor diferente de cero

En el conjunto de datos de flujos bidireccionales etiquetados para el perfil paramétrico, el descriptor *qt* corresponde con el requerimiento de relacionar el comportamiento del tráfico con la percepción general percibida. Este descriptor es agregado de acuerdo con el mecanismo de etiquetado definido en la estructura de preparación de datos para el perfil paramétrico. Los 15 descriptores restantes corresponden a los descriptores válidos inicialmente identificados (Tabla 4.2.6), con excepción de *ts1*, *ts2*, *te1* y *te2*, que han sido unificados y nombrados como *ts* y *te*.

Adicionalmente, se aplicó la técnica de información mutua con el ánimo de conocer el grado de relevancia de cada característica numérica en la predicción del valor objetivo (i.e. *qt*). Valores altos implican un grado mayor de relevancia de la característica como predictor sobre el descriptor *qt*. La Tabla 4.2.20 presenta los valores obtenidos para los descriptores numéricos y la Figura 4.2.33 una imagen visual de los resultados.

**Tabla 4.2.20.** Relevancia de los descriptores numéricos de tráfico sobre la variable *qt*.

<b>td</b>	<b>sp</b>	<b>dp</b>	<b>pr</b>	<b>tos</b>	<b>pkt</b>	<b>byt</b>	<b>fl</b>	<b>bpp</b>	<b>pps</b>	<b>bps</b>
0.227	1.005	0.933	0.027	0.076	0.175	0.342	0.176	0.261	0.138	0.234



**Figura 4.2.33.** Relevancia de descriptores numéricos de tráfico sobre la variable objetivo *qt*.

En este caso, los descriptores con mayor relevancia son tanto los puertos origen como destino (i.e. *sp*, *dp*), y el descriptor con menos relevancia es el protocolo (i.e. *pr*). Sin embargo, la eliminación del descriptor *pr* no es una estrategia adecuada teniendo en cuenta que este describe la forma de conexión de cada uno de los flujos bidireccionales; además, su valor de relevancia no es cero o muy cercano a cero.

Es importante resaltar que la técnica de información mutua ha sido adaptada para problemas de regresión con valores de entrada numéricos [199].

Finalmente, el grado de aplicabilidad de las técnicas de reducción de la dimensionalidad es bajo para este conjunto de datos, principalmente por ser los descriptores recolectados los mínimos para el análisis de tráfico de la red.

## ii. Limpieza de datos

Para el conjunto de datos de tráfico, todas las técnicas del marco general fueron aplicadas. La Figura 4.2.34 presenta el reporte respectivo.

**Dimensión inicial**  
(1410563, 16)

```

ts      1251062      12 atributos numéricos
te      1241451      >Threshold=0.00, Features=12 -->name: []
td      134019      >Threshold=0.05, Features=12 -->name: []
sa      117441      >Threshold=0.10, Features=12 -->name: []
da      28465       >Threshold=0.15, Features=12 -->name: []
sp      64262       >Threshold=0.20, Features=12 -->name: []
dp      55716       >Threshold=0.25, Features=12 -->name: []
pr       5         >Threshold=0.30, Features=12 -->name: []
tos     51         >Threshold=0.35, Features=12 -->name: []
pkt     5706       >Threshold=0.40, Features=12 -->name: []
byt     66553      >Threshold=0.45, Features=12 -->name: []
fl      216        >Threshold=0.50, Features=12 -->name: []
bpp     1459      ---OUTPUT:
pps     1242      columnas a eliminar [] con Threshold=0.0
bps     67345
qt      308627
dtype: int64
---OUTPUT:
Atributos a eliminar:
[]
  
```

a) Valores únicos

b) Pocos valores con baja varianza

-->Duplicados: False

```

-->Detección de valores atípicos con estrategia Local Outlier Factor -
---OUTPUT
DataSet_lof: (1304807, 16) - Registros eliminados: 105756
  
```

c) Duplicados

d) Valores atípicos – LOF

```

-->Cantidad de valores perdidos 0 valor
ts      0      NOTA: No se convierte a NaN attr-tos/qt por ser un comportamiento váli
te      0      -->Cantidad de valores NaN - %Total - iteration method
td      45485  > ts, Missing: 0 (0.0%)
sa      0      > te, Missing: 0 (0.0%)
da      0      > td, Missing: 45485 (3.5%)
sp      3989  > sa, Missing: 0 (0.0%)
dp      462   > da, Missing: 0 (0.0%)
pr      0     > sp, Missing: 3989 (0.3%)
tos     961058 > dp, Missing: 462 (0.0%)
pkt     0     > pr, Missing: 0 (0.0%)
byt     0     > pkt, Missing: 0 (0.0%)
fl      0     > byt, Missing: 0 (0.0%)
bpp     0     > fl, Missing: 0 (0.0%)
pps     385709 > bpp, Missing: 0 (0.0%)
bps     45620 > pps, Missing: 385709 (29.6%)
qt      0     > bps, Missing: 45620 (3.5%)
---OUTPUT:
DataSet_miss: (1259322, 16) - Registros eliminados: 45485
  
```

e) Valores perdidos

**Dimensión final**

(1259322, 16)

**Figura 4.2.34.** Reporte de la tarea de limpieza para el conjunto de datos de tráfico – perfil paramétrico.

De acuerdo con la Figura 4.2.34, ningún descriptor de tráfico presenta un valor único ni baja varianza (ver figuras 4.2.34a y 4.2.34b). De igual manera, no existe en el conjunto de datos observaciones duplicadas que resulten redundantes para el entrenamiento de los modelos de predicción. Para los valores atípicos, la técnica de factor de valor atípico local ha eliminado 105.756 registros del conjunto de datos de tráfico, los cuales representan observaciones con valores inusuales en la monitorización de tráfico de red.

Finalmente, los atributos *td*, *sp*, *dp*, *tos*, *pps*, *bps* contienen cierta cantidad de valores cero, correspondientes a registros con atributos no monitorizados por el nodo de recolección en una ventana de tiempo específica. Sin embargo, el valor cero no necesariamente significa la no monitorización del parámetro; es decir, para el parámetro *tos* el valor cero tiene un significado particular, el cual se centra en otorgar al nodo la capacidad de tratamiento específico al flujo; esto es, un flujo con capacidades básicas dentro de la red para su enrutamiento [200]. En términos de QoS, un valor cero de *tos* significa reservar los recursos mínimos para dicho flujo [200]. En consecuencia, todos los flujos marcados con  $tos = 0$  representan servicios OTT a los cuales se asigna una cantidad mínima de QoS dentro de la red monitorizada y que no tienen una prioridad dentro del esquema de enrutamiento del nodo de recolección del tráfico. En ese sentido, los valores cero en el parámetro *tos* deben ser tratados de acuerdo con dicho comportamiento.

Adicionalmente, el atributo *td* con valores cero no significa que no haya habido una monitorización para ese flujo; sino que corresponde a una mala detección de los tiempos de inicio y fin del flujo de tráfico, resultando en medición de atributos con valores probablemente erróneos. Los tiempos de inicio y fin del flujo están en un orden de precisión de milisegundos, por lo que tiempos idénticos de inicio y fin en un flujo podrían afectar el cálculo de otro parámetro (e.g. *bps*, *pps*). En consecuencia, las observaciones con valores cero en el atributo de *td* deberían ser eliminadas.

### iii. Construcción de nuevos datos

Para el conjunto de datos de tráfico no se aplicó ninguna técnica de ingeniería de características, pero sí fueron generados unos descriptores adicionales que amplían el contexto del tráfico de la red; esto es:

- Generación del descriptor de flujos bidireccionales *fl*, que representa la cantidad de flujos de ida y vuelta para una comunicación usuario-servicio.
- Generación de los descriptores *bpp*, *bps*, *pps*, los cuales determinan la cantidad de datos de tráfico consumidos en cada uno de los flujos bidireccionales.
- Generación del atributo *qt* que representa la evaluación conjunta de la percepción de la calidad de los usuarios para un conjunto de flujos bidireccionales que transitan en la red en un tiempo activo de diferentes sesiones.

### iv. Integración de datos

Para el conjunto de datos de tráfico, la adición fue empleada para unificar los registros obtenidos para cada intervalo de monitorización (i.e. 5 min) y en toda la ventana de recolección (i.e. 5 meses); mientras que la fusión de datos fue empleada para unificar el conjunto de datos de tráfico con el valor de la evaluación general de la percepción de la calidad. La fusión de datos consiste en unificar dos conjuntos de datos con registros similares, pero con atributos diferentes [60].

### v. Formateo de datos

Para el conjunto de datos de tráfico, se emplearon varias técnicas de transformación de datos; esto es:

- Completitud de valores perdidos, a través de la estrategia de valor frecuente.
- Eliminación de valores atípicos, por medio de la técnica LOF.
- Normalización de los datos.
- Escalamiento numérico, a través de la técnica por normalización.
- Modificación gaussiana, por medio de transformación de cuantiles con estrategia normal o uniforme. Esto debido al comportamiento de los datos de tráfico muy alejado de una distribución normal.

### F. Estructura del módulo de Preparación de datos

El módulo de Preparación de datos del modelo tiene el objetivo de secuenciar la ejecución de las tareas de preparación más adecuadas para cada conjunto de datos de acuerdo a su estructura, valores y comportamiento. En ese sentido, la Figura 4.2.35 presenta la implementación de los componentes del módulo de Preparación de datos para el modelo de correlación.

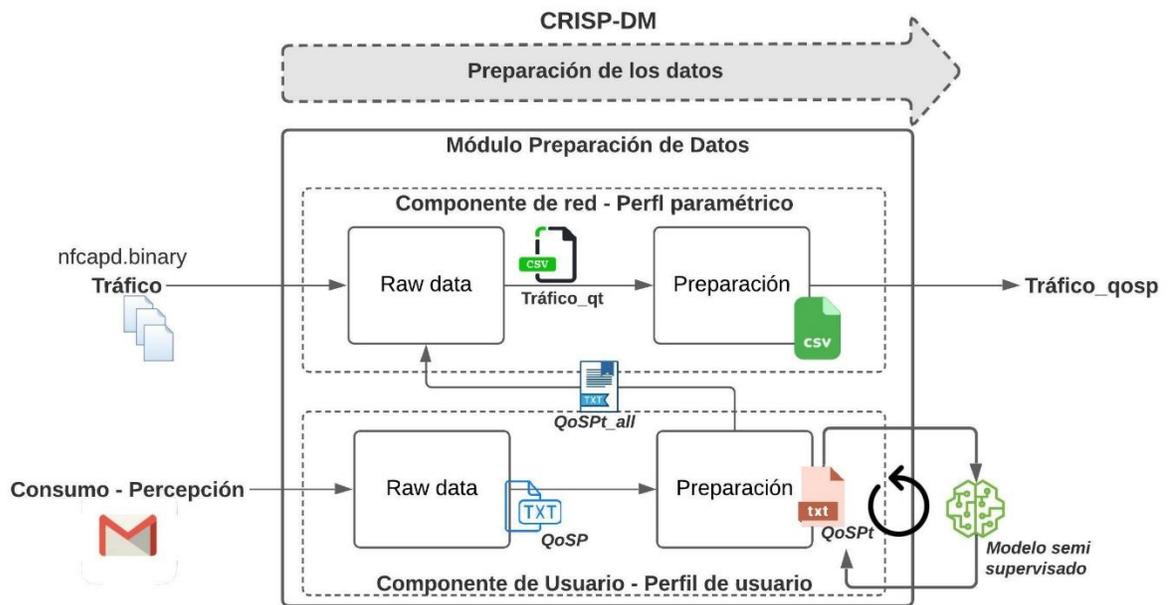


Figura 4.2.35. Módulo de Preparación de datos del modelo de correlación.

El módulo de Preparación de datos del modelo es implementado por dos componentes. El primero, Componente de usuario, representa las técnicas y métodos para transformar los datos del perfil del usuario en términos de estructura y contenido para la fase de modelado semisupervisado, y el método de obtención del descriptor *qt* para el etiquetado de los datos de tráfico; el segundo, Componente de red, implementa las técnicas y métodos para transformar los datos del perfil paramétrico en estructura y contenido para la fase del modelado predictivo de la percepción de la calidad. Para ambos componentes, se definieron dos bloques. Un bloque Raw data, que realiza la lectura y la adecuación de la estructura matricial de los datos, y un bloque Preparación, que ejecuta las tareas específicas del marco general de la preparación de datos de acuerdo con su grado de aplicación (ver Tabla 4.2.17).

#### i. Componente de usuario – Perfil de usuario

Luego de la monitorización y recolección de los datos de consumo y percepción de la calidad de los servicios por parte de los usuarios, los datos son entregados a dos boques de preparación (Figura 4.2.36). El primero, Raw data, realiza la lectura de los datos crudos obtenidos y les asigna un formato matricial. El segundo, Preparación, ejecuta tareas de limpieza y de transformación con el ánimo de adaptarlos a los algoritmos de aprendizaje automático.

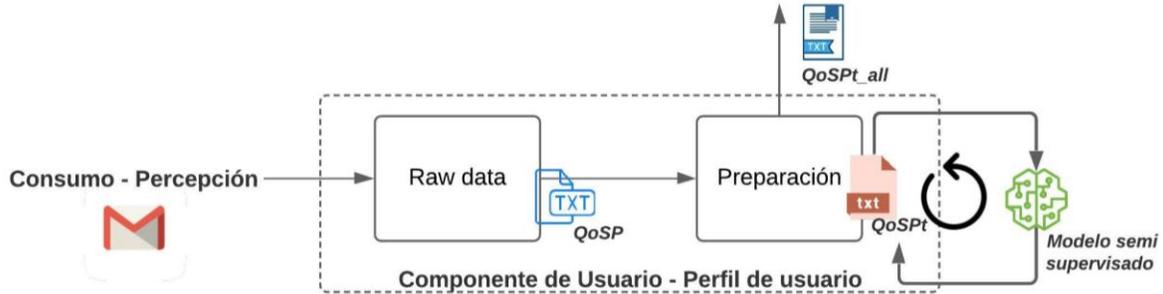


Figura 4.2.36. Componente de usuario – perfil de usuario (Módulo Preparación de datos)

### ➤ Bloque Raw data

La Figura 4.2.37 presenta la implementación del bloque *Raw data* para los datos recolectados. Los datos en crudo son procesados y luego estructurados en formato matricial (i.e. bloques funcionales Lectura y Formato matricial, respectivamente). El bloque funcional de *Lectura* permite obtener del servidor de correo electrónico los mensajes que contienen los datos de consumo y de percepción de la calidad de los servicios para cada sesión de usuario. El bloque funcional *Formato Matricial* tiene las funciones de: eliminación de caracteres especiales, generación de una estructura matricial, y unificación de estructuras matriciales en un solo conjunto de datos. El resultado final es un conjunto de datos estructurado con valores de calificación, nombres de servicio, y tiempos de inicio y fin de la sesión (i.e. QoSP). Este conjunto de datos final es empleado para realizar parte de la fase de comprensión de datos según la metodología CRISP-DM (i.e. exploración de los datos).

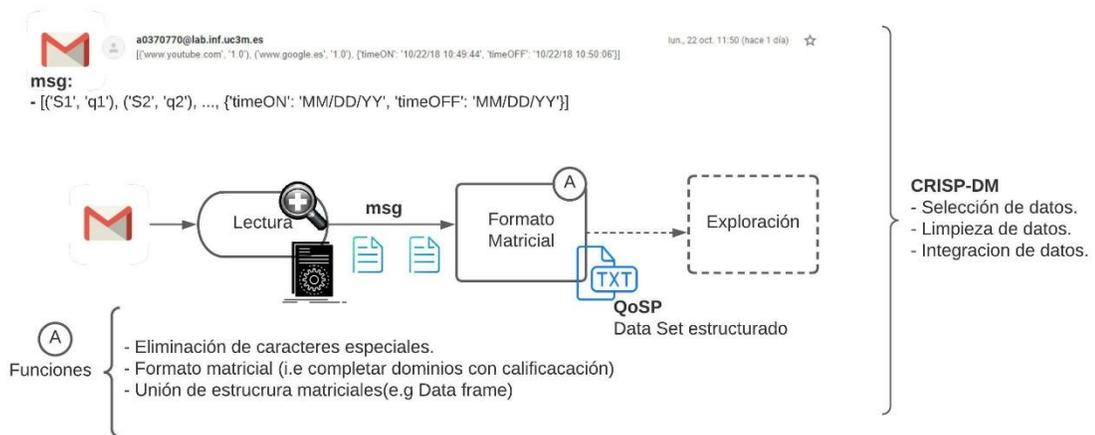


Figura 4.2.37. Implementación bloque Raw data – perfil de usuario (Módulo Preparación de datos)

Las funciones implementadas ajustan la estructura de datos del perfil de usuario a un formato matricial para su análisis y entrenamiento del modelo; esto es:

- Eliminación de caracteres especiales: Consiste en la eliminación de aquellos caracteres propios del formato de recolección de datos que no aportan información en el conjunto de datos (e.g. paréntesis)
- Generación de estructura matricial: Consiste en completar la estructura matricial,  $n \times m$ , de los datos del perfil del usuario para su posterior análisis y desarrollo de los modelos. Lo anterior se realiza teniendo en cuenta que no todos los usuarios consumen la misma cantidad de servicios.
- Unificación de estructuras matriciales: Realiza la adición de datos de todas las estructuras matriciales generadas día a día para todo el periodo de recolección de los datos.

### ➤ Bloque Preparación

La Figura 4.2.38 presenta la implementación del bloque Preparación para los datos estructurados de consumo del usuario. El bloque funcional *Generación descriptor qt* implementa un modelo matemático del cálculo de la evaluación final para una sesión de usuario. El bloque funcional *Transformación de datos* ejecuta la secuencia de transformadas a ser aplicadas al conjunto de datos para su adecuación. Finalmente, el bloque funcional *Esquema de actualización de datos* realiza la división de los datos de la percepción de la calidad en datos etiquetados y no etiquetados, y agrega los valores de la percepción de la calidad predichos por el modelo del módulo supervisado al conjunto de datos final.

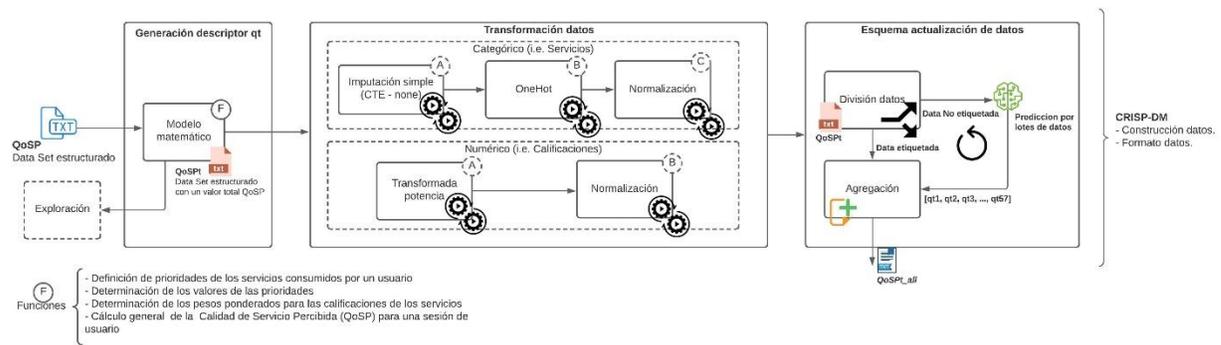


Figura 4.2.38. Implementación del bloque Preparación – perfil de usuario (Módulo Preparación de datos)

### Bloque funcional Generación descriptor qt

Este bloque lleva a cabo las funciones del cálculo del valor de la evaluación general de la percepción de la calidad para toda la sesión del usuario. Para ello, se definió un esquema de prioridades y de valoración a partir del comportamiento de consumo del usuario. La ecuación 9 describe el modelo matemático definido.

$$QoSPt = \sum_{k=1}^P Wij^{(k)} * Qij^{(k)} \quad (9)$$

$Wij^{(k)}$  = Peso del servicio  $i$  consumido por un usuario en la sesión  $j$  y con prioridad  $k$ .

$Qij^{(k)}$

= Calificación del servicio  $i$  consumido por un usuario en la sesión  $j$  y con prioridad  $k$

$$Wij^{(k)} = \frac{Vj^{(k)}}{\sum_{k=1}^P Vj^{(k)}}, \text{ con } \sum_{k=1}^P Wij = 1 \quad (9a)$$

$Vj^{(k)} = n(Sc)_j + 1 - k$ , donde  $n(Sc)_j = p_j$

$$\sum_{k=1}^{P_j} k = \frac{p(p+1)}{2} \quad (9b)$$

$V_j^{(k)}$  = Valor de la prioridad  $k$  del servicio consumido por un usuario en la sesión  $j$

$Sc$  = conjunto de servicios consumidos por un usuario en la sesión  $j$ .

$n(Sc)$  = cardinalidad de  $Sc$

$kj$  = conjunto de prioridades de los servicios consumidos por un usuario en la sesión  $j$

$p$  = valor numérico de prioridad asignado al servicio  $S_n$

$$Sc = \{S_1, S_2, S_3, \dots, S_n\}$$

$$kj = \{1, 2, 3, \dots, p\}$$

Lo anterior denota que el valor total de la  $QoSPt$  está determinado por los pesos ponderados de cada una de las calificaciones parciales de los servicios consumidos por el usuario en su respectiva sesión. De igual manera, los pesos ponderados de los servicios dependen del valor de la prioridad asignada a cada servicio, la cual está determinada por el tiempo de consumo del mismo durante la sesión; esto es: si un usuario en una sesión ha consumido tres servicios, entonces tendrá una mayor prioridad (e.g.  $k = 1$ ), y por tanto un valor de prioridad mayor (e.g.  $V^{(1)} = 3$ ), aquel servicio con el mayor tiempo de consumo. Para los dos servicios restantes, la prioridad y el valor de prioridad dependerán del tiempo de consumo por parte del usuario; se asigna la prioridad siguiente al servicio con el tiempo de consumo intermedio, y la prioridad menor al servicio con el menor tiempo de consumo. La Figura 4.2.39 presenta el diagrama de procesos del cálculo del descriptor  $qt$ .

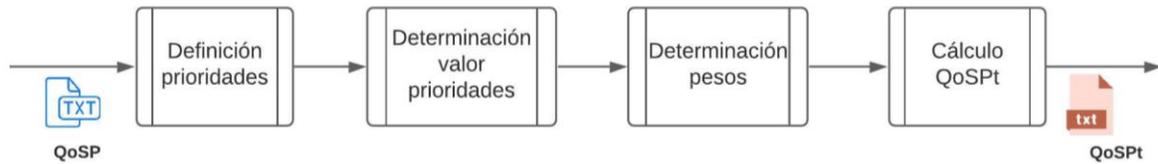


Figura 4.2.39. Procesos del modelo matemático para el cálculo QoSPT

El proceso del cálculo del descriptor  $qt$  inicia con *Definición de prioridades*, la cual consiste en establecer el conjunto de prioridades a partir del comportamiento de consumo en cada una de las sesiones de los usuarios. Posteriormente, se halla el valor de cada prioridad en una matriz de prioridades (i.e. *Determinación valor prioridades*); luego, la matriz de peso es calculada de acuerdo con el valor de cada prioridad (i.e. *Determinación de pesos*). Finalmente, la función de *Cálculo QoSPT* cuantifica el valor de la evaluación general de la percepción de la calidad de los servicios consumidos por el usuario en cada una de sus sesiones. Para ejemplificar el proceso descrito, se esboza a continuación un escenario para cuatro sesiones diferentes.

### Definición de prioridades

a) Se tienen cuatro sesiones de usuario con los siguientes servicios consumidos:

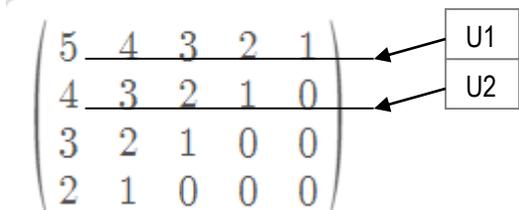
- $U_1$  con  $Sc = \{S_1, S_2, S_3, S_4, S_5\}$ ; e.g.,  $S_1$ : Netflix
- $U_2$  con  $Sc = \{S_1, S_2, S_3, S_4\}$ ; e.g.,  $S_1$ : WhatsApp
- $U_3$  con  $Sc = \{S_1, S_2, S_3\}$ ; e.g.,  $S_1$ : Mail
- $U_4$  con  $Sc = \{S_1, S_2\}$ ; e.g.,  $S_1$ : Skype

b) Para cada sesión, se define un conjunto de prioridades; esto es:

- $k_1 = \{1, 2, 3, 4, 5\}$ ; donde 1 denota la prioridad más alta para el servicio con mayor tiempo consumido (i.e.  $S_1$ ) – Netflix tendrá la prioridad más alta para el usuario en la sesión  $U_1$ .
- $k_2 = \{1, 2, 3, 4\}$ ; donde 1 denota la prioridad más alta para el servicio con mayor tiempo consumido (i.e.  $S_1$ ) – WhatsApp tendrá la prioridad más alta para el usuario en la sesión  $U_2$
- $k_3 = \{1, 2, 3\}$ ; donde 1 denota la prioridad más alta para el servicio con mayor tiempo consumido (i.e.  $S_1$ ) – Mail tendrá la prioridad más alta para el usuario en la sesión  $U_3$
- $k_4 = \{1, 2\}$ ; donde 1 denota la prioridad más alta para el servicio con mayor tiempo consumido (i.e.  $S_1$ ) – Skype tendrá la prioridad más alta para el usuario en la sesión  $U_4$

**Determinación valor de prioridades**

c) Se construye la matriz de valor de prioridades para el conjunto de las sesiones ( $V_j^{(k)}$ )



**Determinación de pesos**

d) Se calcula el vector de suma de prioridades.

$$\vec{ksum} = \sum_{k=1}^{p_j} k = \frac{p(p+1)}{2}$$

$$\begin{pmatrix} 15 \\ 10 \\ 6 \\ 3 \end{pmatrix}$$

e) Se halla la matriz de pesos ponderados

$$W = \frac{V^{(k)}}{Ksum}$$

$$\begin{pmatrix} \frac{5}{15} & \frac{4}{15} & \frac{3}{15} & \frac{2}{15} & \frac{1}{15} \\ \frac{4}{10} & \frac{3}{10} & \frac{2}{10} & \frac{1}{10} & 0 \\ \frac{3}{6} & \frac{2}{6} & \frac{1}{6} & 0 & 0 \\ \frac{2}{3} & \frac{1}{3} & 0 & 0 & 0 \end{pmatrix}$$

### Cálculo QoSPT

- f) Se construye la matriz de calificaciones a partir de las calificaciones de cada servicio en cada una de las sesiones de los usuarios ( $Q_{ij}^{(k)}$ )

$$\begin{pmatrix} q1 & q2 & q3 & q4 & q5 \\ q1 & q2 & q3 & q4 & 0 \\ q1 & q2 & q3 & 0 & 0 \\ q1 & q2 & 0 & 0 & 0 \end{pmatrix}$$

- g) Se realiza el producto entre las matrices de pesos ponderados y la matriz de calificaciones; esto es:

$$QoSPT = W * QoSP^{(T)}$$

$$\begin{pmatrix} \frac{5}{15} \cdot q1 & \frac{4}{15} \cdot q2 & \frac{3}{15} \cdot q3 & \frac{2}{15} \cdot q4 & \frac{1}{15} \cdot q5 \\ \frac{4}{10} \cdot q1 & \frac{3}{10} \cdot q2 & \frac{2}{10} \cdot q3 & \frac{1}{10} \cdot q4 & 0 \\ \frac{3}{6} \cdot q1 & \frac{2}{6} \cdot q2 & \frac{1}{6} \cdot q3 & 0 & 0 \\ \frac{2}{3} \cdot q1 & \frac{1}{3} \cdot q2 & 0 & 0 & 0 \end{pmatrix}$$

### Bloque funcional Transformación de datos

Este bloque define la secuencia de transformación de los datos con el ánimo de ajustarlo a los algoritmos de aprendizaje. Para ello, los descriptores son separados de acuerdo a su naturaleza (i.e. categórico, numéricos) (Figura 4.2.38).

Para los descriptores categóricos, la secuencia aplicada es: Imputación simple (A), codificación *One-hot* (B), y Normalización (C). La primera, *Imputación simple*, completa la matriz cuando una sesión no alcanza el número de servicios que pueden ser calificados (i.e. 5 servicios). Esta imputación se realiza con un valor constante que denota que no hay más consumo por parte del usuario sino aquel que fue monitorizado en su sesión (i.e. *none*); es decir, para un usuario que ha consumido tres servicios, el valor a imputar será *none* para los servicios restantes que completa la matriz. La segunda, *One-hot*, codifica cada valor categórico a un valor numérico representado por una secuencia de unos y ceros; cada descriptor categórico tiene una secuencia diferente. La tercera, *Normalización*, escala los valores numéricos entre 0 y 1 de acuerdo con la norma  $L_2$  [201].

Para los descriptores numéricos, la secuencia aplicada es: Transformada de potencia (A) y Normalización (B). La primera (Transformada de potencia), modifica el comportamiento de la distribución de los datos hacia una distribución más gaussiana. De acuerdo con la fase de comprensión de los datos, estos tienen un comportamiento cercano al normal con presencia de sesgo. En consecuencia, se modifica la distribución de los datos con la estrategia Yeo-Johnson. La segunda (Normalización), escala los valores numéricos entre 0 y 1 de acuerdo con la norma  $L_2$  [201].

Al final del bloque funcional de Transformación de datos, un conjunto de datos con dimensión (1.256, 938) representa el conjunto de datos preparado del perfil del usuario que el componente semisupervisado usará para

el entrenamiento de los modelos. Esta dimensión se alcanza luego de ejecutar las tareas de preparación sobre un conjunto de datos con dimensión (1.256, 28); aquí, los descriptores de tiempo de inicio y fin de la sesión han sido separados por descriptores numéricos que representan: mes, día, hora, minutos, segundos, día de la semana, semana del año, y hora, minutos y segundos de duración de la sesión (i.e. 17 descriptores de contexto adicionales sobre los descriptores del conjunto de datos inicial).

### Bloque funcional Esquema actualización de datos

Este bloque (Figura 4.2.38) implementa funciones compartidas con el componente semisupervisado del perfil de usuario en el módulo de Modelado, con el ánimo de fijar un valor de evaluación general de la percepción de la calidad en aquellas sesiones donde ningún servicio fue calificado. Para ello, el bloque funcional divide el conjunto de datos de la percepción de la calidad en datos etiquetados y no etiquetados (i.e. dimensiones de 114 y 1.142, respectivamente). El subconjunto de datos no etiquetados es enviado al modelo predictivo previamente entrenado en la fase de modelado. Este modelo predice para un lote de datos de este subconjunto, el valor del descriptor *qt*; posteriormente, los valores de *qt* predichos son enviados al esquema de actualización para que sean agregados al subconjunto de datos etiquetados. El proceso se repite hasta completar todos los valores de *qt* para el subconjunto de datos no etiquetados. Al final, un conjunto de datos etiquetados con dimensión (1.256, 13) representa la evaluación general de los usuarios en cada una de sus sesiones.

#### ii. Componente de red – Perfil paramétrico

Luego de la monitorización y recolección de los datos de tráfico de la red, estos son entregados a dos bloques de preparación (Figura 4.2.40). El primero, Raw data, realiza la lectura de los datos crudos obtenidos y les asigna un formato matricial. El segundo, Preparación, ejecuta tareas de limpieza y de transformación con el ánimo adaptarlos a los algoritmos de aprendizaje automático.

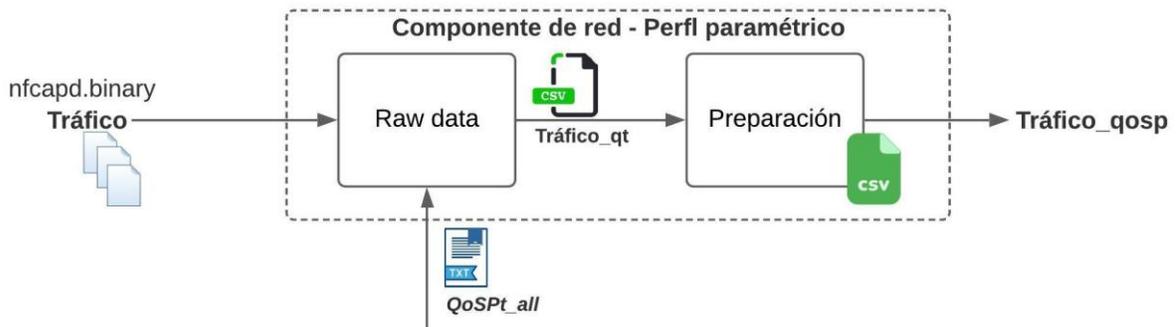


Figura 4.2.40. Componente de red – perfil paramétrico (Módulo de Preparación de datos)

#### ➤ Bloque Raw data

La Figura 4.2.41 presenta la implementación del bloque *Raw data* para los datos de tráfico recolectados. El bloque funcional de *Lectura y Conversión* obtiene los descriptores de los flujos que representan las conexiones bidireccionales entre los usuarios y los servicios (e.g. paquetes, bps, dirección IP origen y destino, puertos, cantidad de flujos, tos); la *Conversión* hace que todos los descriptores recolectados sean valores planos (i.e. valor numérico). De igual manera, el descriptor *tos* es obtenido para cada uno de los flujos, representando la manera en que el flujo es tratado por el sistema de QoS configurado en el nodo de recolección (i.e. enrutador). El bloque funcional *Formato matricial* se encarga de estructurar los datos de los flujos bidireccionales en una

matriz. El bloque funcional *Integración DataSets* realiza el etiquetado de los flujos bidireccionales con el valor del descriptor *qt* obtenido de las sesiones de los usuarios, entregando el conjunto de datos estructurado *tráfico-qt*. Este conjunto de datos final es empleado para realizar parte de la fase de comprensión de datos según la metodología CRISP-DM (i.e. exploración de los datos).

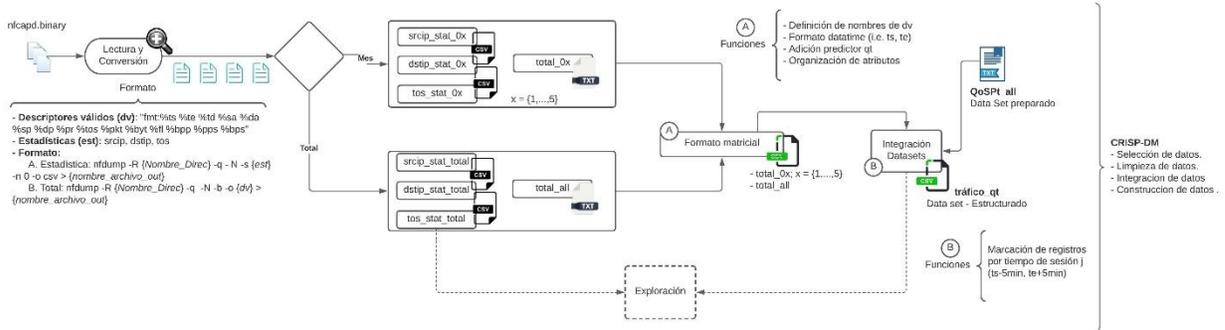


Figura 4.2.41. Implementación del bloque Raw data – perfil paramétrico (Módulo Preparación de datos)

### Funciones del bloque Lectura y Conversión

La función de implementada permite la lectura de los archivos binarios y dar formato específico a cada uno de los descriptors del flujo. Para ello, los descriptors válidos fueron formateados de acuerdo con el requerimiento específico; a saber:

- Agrupamiento de flujos por conexiones bidireccionales: -b
- Lectura de los descriptors válidos dentro del archivo binario: -o
- Conversión a valores numéricos: -N
- Eliminación de líneas de información de inicio y fin del archivo binario: -q

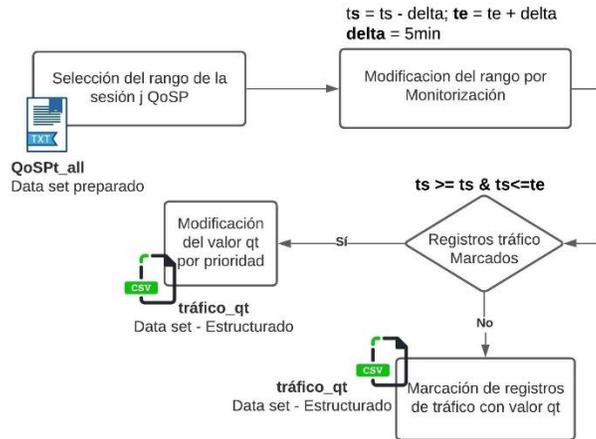
### Funciones del bloque funcional Formato matricial

Las funciones implementadas ajustan la estructura de datos del perfil de usuario a un formato matricial para su análisis y entrenamiento del modelo; esto es:

- Definición de nombres de los descriptors válidos: Consiste en nombrar cada descriptor de acuerdo con la variable monitorizada de tráfico.
- Formato *datetime*: Consiste en otorgar un formato de fecha para los descriptors *ts* y *te*.
- Adición del predictor *qt*: Consiste en generar el descriptor de la evaluación general de la percepción de la calidad para cada uno de los flujos bidireccionales; el descriptor inicia con un valor de cero.
- Organización de atributos: Consiste en ordenar los descriptors, tanto de tráfico como de percepción de la calidad.

### Funciones del bloque funcional Integración Datasets

La Figura 4.2.42 presenta el proceso empleado para el etiquetado de los datos de flujo bidireccional en cada una de las sesiones de los usuarios; esto es, la fusión de datos de tráfico y de percepción de la calidad a través de un identificador clave. Los pasos realizados son los siguientes:



**Figura 4.2.42.** Proceso de fusión de datos de tráfico y evaluación general de la percepción de la calidad.

- Selección del rango de la sesión j QoSP: Consiste en determinar el intervalo de tiempo para cada una de las sesiones de usuario. Este rango [ts, te] es el identificador para la fusión de datos teniendo en cuenta que la dirección IP no fue capturada por motivos de privacidad.
- Modificación del rango por monitorización: Consiste en adecuar el rango de la sesión, con un valor delta, de acuerdo con la configuración de monitorización del protocolo Netflow (i.e. 5 minutos).
- Registros tráfico marcados: Consiste en revisar si el valor qt en el conjunto de datos de tráfico ya ha sido valorado o sigue con su valor inicial cero.
- Marcación de registros de tráfico con valor qt: Consiste en marcar todos los registros bidireccionales dentro del rango de la sesión j con el valor del descriptor qt.
- Modificación del valor qt por prioridad: Consiste en modificar el valor de qt para aquellos registros bidireccionales que han sido marcados previamente por usuario en una sesión j.

Para esta última función, se definió un modelo de valoración de qt para flujos bidireccionales (ecuación 10); esto es:

$$QoSP_j = W_j^{(p)} * QoSP'_j + W_i^{(p)} * QoSP_i \quad (10)$$

$W_j^{(p)}$  = peso ponderado del plan contratado por el usuario j

$W_i^{(p)}$  = peso ponderado del plan contratado por el usuario i

$QoSP'_j$  = calificación total anterior registrada por el usuario j

$QoSP_i$  = calificación total registrada por el usuario i

$$W_j^{(p)} = \frac{V_j^{(p)}}{V_j^{(p)} + V_i^{(p)}} \quad (10a)$$

$$W_i^{(p)} = \frac{V_i^{(p)}}{V_j^{(p)} + V_i^{(p)}} \quad (10b)$$

$V_j^{(p)}$  = Valor de la categoría del plan contratado por el usuario j (asignado por el telco)

$V_i^{(p)}$  = Valor de la categoría del plan contratado por el usuario i (asignado por el telco)

El modelo de valoración se establece teniendo en cuenta que diferentes flujos bidireccionales en diferentes sesiones de usuario están compartiendo recursos dentro de la red del operador (e.g. ancho de banda). En ese sentido, la evaluación general de la percepción de la calidad para una sesión  $j$  de un usuario es afectada por la evaluación general de la percepción de la calidad de una sesión  $i$  de otro usuario. Lo anterior se presenta cuando los usuarios consumen servicios en tiempos de sesión compartidos (e.g. una sesión de usuario de 9:00 a.m. a 10:00 a.m., y otra sesión de usuario de 9:30 a.m. a 10:30 a.m.; comportamiento real de consumo de servicios).

Los valores de la categoría son definidos por la Telco de acuerdo con el plan contratado por el usuario; e.g., el plan de servicio con mayores prestaciones tendría el valor de la categoría más alto. Para la implementación, se han definido cuatro categorías de acuerdo con los planes de servicio de un operador móvil local; esto es:

- Para cuatro planes ofrecidos por un operador local (i.e. plan ilimitado, plan 150GB, plan 25 GB, y plan 15GB) [202], se simularon cuatro categorías con valores diferentes (i.e. valores de 4, 3, 2, 1 para los planes de mayor a menor prestaciones, respectivamente). El valor de cada categoría del plan de servicio es asignado por el operador de acuerdo con sus políticas o estrategias de negocio.
- Se simuló una selección aleatoria del valor de la categoría para el cálculo de cada uno de los pesos  $W_j^{(p)}$  y  $W_i^{(p)}$ .

Finalmente, los flujos bidireccionales que han sido etiquetados con  $qt$  representan la relación entre la QoS entregada por el operador y la QoE percibida del usuario. La QoS entregada por el operador está definida por el descriptor  $tos$  que marca a cada uno de los flujos, y la QoE percibida del usuario está definida por el descriptor  $qt$ , que indica la calificación de la calidad total percibida por el usuario luego de terminar una sesión

### ➤ Bloque de Preparación

La Figura 4.2.43 presenta la implementación del bloque de Preparación para el conjunto de datos estructurados *tráfico-qt* de los usuarios. El bloque funcional *Limpieza básica* implementa la técnica de detección de registros duplicados. El bloque funciona *Limpieza especializada* ejecuta técnicas más robustas de limpieza de datos como la identificación de valores atípicos y marcación de datos perdidos. El bloque funcional *Transformación de datos* ejecuta la secuencia de transformadas a ser aplicadas al conjunto de datos para su adecuación.

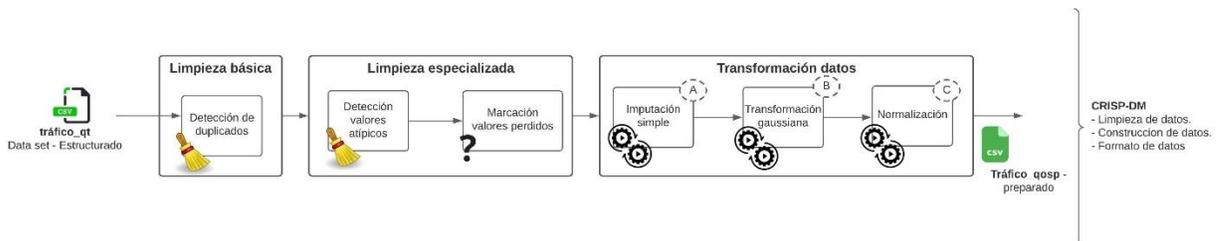


Figura 4.2.43. Implementación del bloque Preparación – perfil paramétrico (Módulo Preparación de datos)

### Bloque funcional Limpieza básica

Este bloque hace uso de técnicas de limpieza de datos estándar para la revisión general de los valores presentados. Para ello, la función de detección de duplicados identifica observaciones repetidas en el conjunto de datos de tráfico.

### **Bloque funcional Limpieza especializada**

Este bloque hace uso de técnicas más precisas para la revisión de valores que generan ruido o que no han sido reportados por el nodo de recolección. Se emplearon técnicas LOF y de marcación de datos perdidos dentro del conjunto de datos de tráfico. Para el conjunto de datos del perfil paramétrico se generó un reporte (ver sección 4.2.3.2 literal E).

### **Bloque funcional Transformación de datos**

Este bloque hace uso de técnicas de preparación para la adaptación de los atributos en el proceso de entrenamiento de los algoritmos de aprendizaje automático.

Para los descriptores seleccionados del perfil paramétrico la secuencia aplicada es: Imputación simple (A), Transformación gaussiana (B), y Normalización (C). La primera (Imputación simple), asigna el valor más frecuente, en cada descriptor, a los datos marcados como perdidos para dicha característica; la segunda (Transformación gaussiana), modifica la distribución de los datos a través de una transformación cuantil o de punto porcentual. Esta transformación se realiza por el comportamiento altamente sesgado de la distribución de los datos de tráfico. La tercera (Normalización), escala los valores numéricos entre 0 y 1 de acuerdo con la norma  $L_2$  [201].

Como resultado, un conjunto de datos etiquetados con dimensión (1.259.322, 26) representa la estructura de los datos del perfil paramétrico del modelo de correlación. La diferencia de 10 descriptores en comparación con la dimensión final del reporte de limpieza de datos (ver Tabla 4.2.19), radica en que los descriptores  $t_s$  y  $t_e$  han sido separados en horas, minutos, segundos, semana del día, y semana del año con el ánimo de agregar información de contexto en el perfil paramétrico. En efecto, la percepción de la calidad de los servicios difiere del momento del día y de la temporada en que estos son consumidos.

#### **4.2.3.3. Módulo de Modelado**

El modelado es una fase dentro de la metodología CRISP-DM que permite generar modelos predictivos a partir de un conjunto de datos debidamente ajustado a los requerimientos de entrada exigidos por los algoritmos de aprendizaje automático. Para ello, tareas como: selección de técnicas de modelado, generación de un diseño de comprobación, generación de modelos, y evaluación del modelo han sido definidas para el desarrollo de esta fase [60]. La Figura 4.2.44 presenta la implementación de los componentes del módulo de Modelado para el modelo de correlación QoS-QoE.

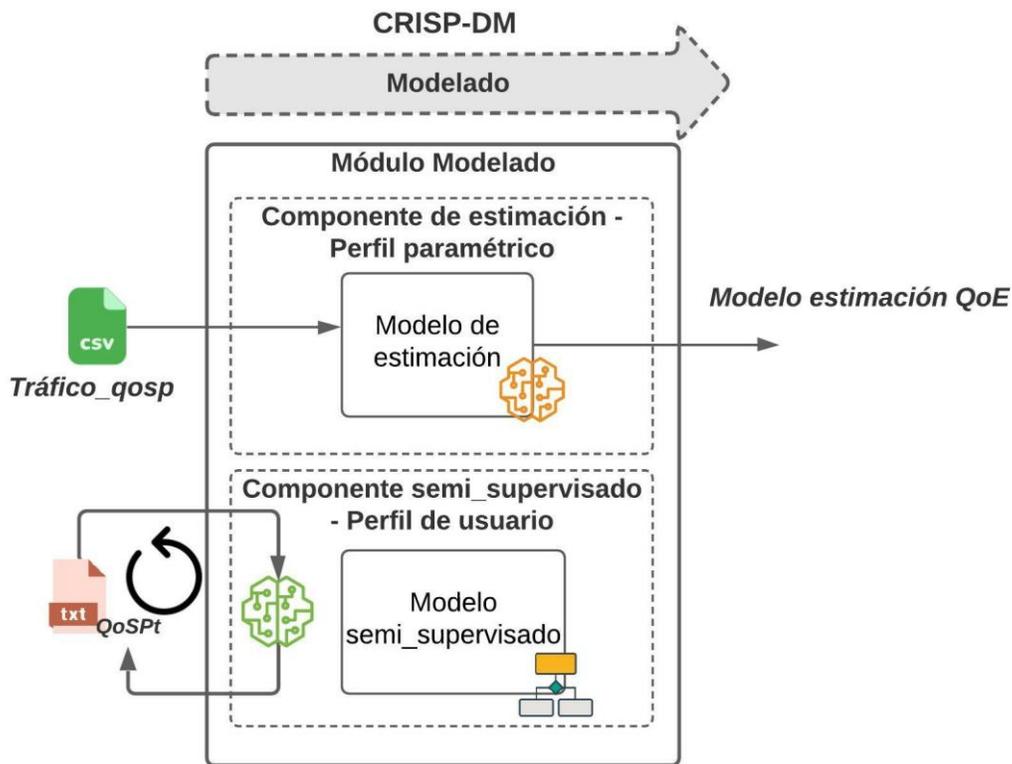


Figura 4.2.44. Módulo de Modelado del modelo de correlación.

El módulo de modelado es implementado por dos componentes. El primero, *Componente semi\_supervisado*, genera un modelo de predicción semisupervisado para etiquetar las sesiones de los usuarios que no han sido calificadas; el segundo, *Componente de estimación*, genera un modelo predictivo supervisado para el perfil paramétrico que estima un valor general de la percepción de la calidad a partir del comportamiento de tráfico para diferentes usuarios luego de haber consumido servicios OTT.

#### A. *Componente semi\_supervisado – perfil de usuario*

Luego de la preparación de los datos del perfil de usuario, estos son entregados a los cuatro bloques desarrollados para la implementación del componente (ver Figura 4.2.45). El primero, *Selección de algoritmos*, realiza una elección de algoritmos de uso general de acuerdo con el problema de aprendizaje automático detectado (i.e. problema de regresión); el segundo, *Evaluación de algoritmos*, determina el diseño de comprobación, el esquema de entrenamiento, y verifica la calidad de un conjunto de algoritmos de aprendizaje automático de uso estandarizado; el tercero, *Entrenamiento del modelo*, realiza el entrenamiento del modelo con el algoritmo de mejor desempeño. Finalmente, el bloque *Semi\_supervisado* predice los valores de la percepción de la calidad para las sesiones no calificadas de los usuarios.

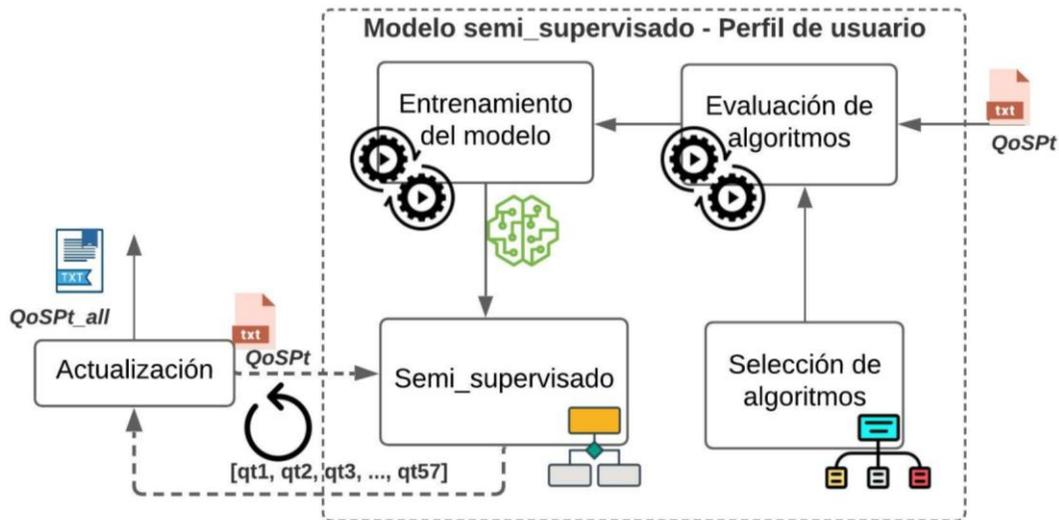


Figura 4.2.45. Componente semi-supervisado – perfil de usuario (Módulo Modelado)

La Tabla 4.2.21 presenta la implementación de tareas generales CRISP-DM en los bloques del Componente semi-supervisado para el perfil de usuario.

Tabla 4.2.21. Implementación de tareas CRISP-DM en el Componente semi-supervisado del perfil de usuario.

Componente Semi-supervisado – perfil de usuario.	Tareas CRISP-DM
Selección de algoritmos	Selección de técnicas de modelado
Evaluación de algoritmos	Generación de un diseño de comprobación, generación de modelos, y evaluación del modelo

### i. Bloque Selección de algoritmos

Para un problema de regresión, donde se debe predecir una variable numérica continua o real [203], los algoritmos de aprendizaje automático más empleados pueden ser clasificados en lineales y no lineales [193]. Los primeros, asumen que la variable objetivo está en función de una combinación lineal de las características o parámetros [204]; los segundos, asumen que no hay una relación lineal entre los parámetros o características y la variable objetivo. En ese sentido, la Tabla 4.2.22 presenta los algoritmos más usados de acuerdo con dicha clasificación para un problema de regresión.

Tabla 4.2.22. Algoritmos de uso recurrente en problemas de regresión.

Algoritmos de aprendizaje automático lineales para un problema de regresión	Algoritmos de aprendizaje automático no lineales para un problema de regresión
Regresión lineal – LR	Vecinos más cercanos (i.e. kNN de regresión) - kNN
Regresión Ridge –Ridge	Árboles de clasificación y regresión - CART
Regresión lineal LASSO – LASSO	Máquinas de vector de soporte de regresión - SVR
Regresión neta elástica - EN	

De igual manera, otros algoritmos dentro del aprendizaje automático son útiles para la construcción de modelos, especialmente para reconocer patrones en el conjunto de datos. En particular, las redes neuronales son una opción válida en problemas de regresión y en esquemas semisupervisados como estrategia de preentrenamiento del modelo. En efecto, para esquemas semisupervisados, donde la cantidad de datos etiquetados es menor que los datos no etiquetados, una estrategia para el entrenamiento inicial del modelo es

optar por preentrenar el modelo con datos no etiquetados, y posteriormente ajustar los parámetros del modelo con los datos etiquetados [205][205]. En ese sentido, se selecciona un regresor perceptrón multicapa (i.e. MLP regresor), y una red neuronal profunda como es sugerido por S. Rezaei et al. en [205].

## ii. Bloque Evaluación de algoritmos

### ➤ Diseño de comprobación

Para la evaluación de los algoritmos de aprendizaje automático seleccionados, se definió un esquema de comprobación con el ánimo de medir la calidad y validez de cada uno de los modelos; esto es (Tabla 4.2.23):

- Algoritmos de modelado perfil de usuario: Presenta las opciones de los algoritmos candidatos en la predicción del descriptor  $qt$  del perfil del usuario.
- Parámetros iniciales: Define los parámetros iniciales de configuración para cada uno de los algoritmos.
- Identificador de configuración de evaluación: Presenta el identificador de la configuración de las pruebas de acuerdo con las técnicas de preparación usadas.
- Métrica de evaluación: Métrica usada para evaluar el desempeño de los algoritmos en relación con la predicción del descriptor  $qt$ .

**Tabla 4.2.23.** Diseño de comprobación

Algoritmos de modelado perfil de usuario	Parámetros iniciales	Identificador de configuración	Métrica de evaluación
Codificador Automático Apilado (SAE, Stacked AutoEncoder)	2 capas escondidas más hiperparámetros por defecto	A1, B2, C3, D4, E5, F6, G7, H8	MAE/MSE
<b>Redes Neuronales (NN)</b>			
SAE con CNN( Convolutional Neural Network)	3 capas escondidas para la red profunda top, más hiperparámetros por defecto	I9, J10, K11, L12, M13, N14, O15, P16	MAE/MSE
DNN (Deep Neural Network)	5 capas escondidas para la red profunda, más hiperparámetros por defecto	Q17, R18, S19, T20, U21, V22, W23, X24	MAE/MSE
MLP	Hiperparámetros por defecto	A1, B2, C3, D4	MAE/MSE
<b>Algoritmos de uso estandarizado</b>			
Regresión lineal	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
Regresión Ridge	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
Regresión lineal LASSO	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
Regresión neta elástica - EN	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
kNN	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
CART	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
SVR	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE

### Algoritmos de modelado del perfil de usuario

Los algoritmos de aprendizaje automático seleccionados pueden agruparse en dos categorías. La primera, *Redes Neuronales*, permite analizar y detectar patrones en el conjunto de datos del perfil de usuario donde se cuenta con una alta dimensionalidad en su estructura; la segunda, *algoritmos de uso estandarizado*, emplea técnicas reconocidas y ampliamente usadas en problemas de regresión.

#### - Redes neuronales.

El conjunto de datos del perfil de servicio cuenta con una estructura de alta dimensionalidad producto de la ejecución de tareas de preparación de datos (ver Tabla 4.2.24), donde comprender la relación entre las características de entrada transformadas puede llegar a ser complejo, y se requiere detectar patrones en los datos que sean útiles en la predicción del descriptor  $qt$ . Adicionalmente, la necesidad de contar con un conjunto de datos etiquetados para todas las sesiones de usuario, requiere el empleo de técnicas semisupervisadas para lograr un etiquetado completo del conjunto de datos del perfil de usuario.

Tabla 4.2.24. Dimensión de los datos dentro de la fase de preparación.

Datos iniciales QoSpt	Preparación de datos QoSpt	
	Agregación de contexto de usuario	Transformación de datos
(1.256, 13): 1.256 sesiones con 12 descriptores y una variable objetivo	(1.256, 27): 1.256 sesiones con 26 descriptores y una variable objetivo. 17 descriptores de contexto a partir de timeOn y timeOff	(1.256, 938): 1.256 sesiones con 938 descriptores transformados para solo datos de entrada.

Una de las técnicas semisupervisadas es el procesamiento previo no supervisado, el cual extrae características principales del conjunto de datos no etiquetado, agrupa previamente los datos, o determina los parámetros iniciales de un procedimiento de aprendizaje supervisado de una manera no supervisada (i.e. Extracción de características, clúster luego etiquetado, y preentrenamiento, respectivamente) [206]. En efecto, autores como S. Rezaei [205] hacen uso de esta técnica para el preentrenamiento del modelo a partir de datos no etiquetados.

El método de preentrenamiento consiste en usar los datos no etiquetados para orientar los parámetros del modelo a una región de interés antes de aplicar aprendizaje supervisado [206]; es decir, iniciar el valor de los parámetros del modelo antes de predecir la variable objetivo de una manera supervisada. Para este método, las técnicas de mayor aplicación son las de aprendizaje profundo, como las Redes de Creencia Profunda (DBN) y Codificadores Automáticos Apilados (SAE). Ambas técnicas tienen el mismo propósito, inicializar los parámetros del modelo supervisado de una manera no supervisada, pero sus algoritmos base y arquitecturas son diferentes (ver Figura 4.2.46). La primera (Figura 4.2.46a), emplea máquinas de Boltzmann restringidas; la segunda (Figura 4.2.46b), hace uso de codificadores automáticos.

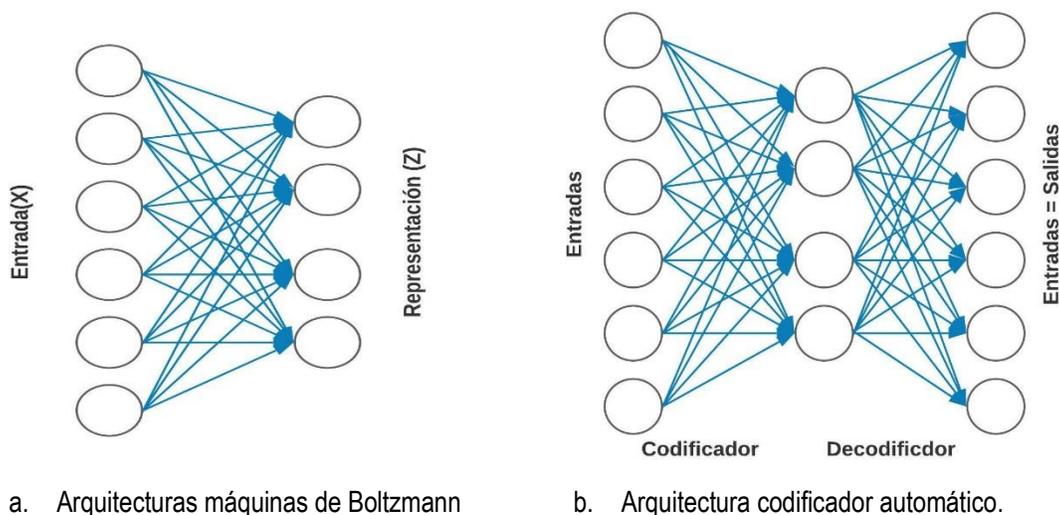


Figura 4.2.46. Arquitecturas de máquinas de Boltzmann y codificador automático  
 Fuente: Adaptada de [207]

En este caso, se ha implementado un SAE con una estrategia por capas astutas (i.e. *Greedy layer-wise*), el cual entrena capa por capa de la red hasta lograr un nivel óptimo de desempeño del algoritmo. Además, el SAE permite copiar la entrada a la salida del modelo a través del aprendizaje de propiedades útiles de los datos de entrada [208]. La Figura 4.2.47 presentan la arquitectura y estructura SAE con *Greedy layer-wise* implementada.

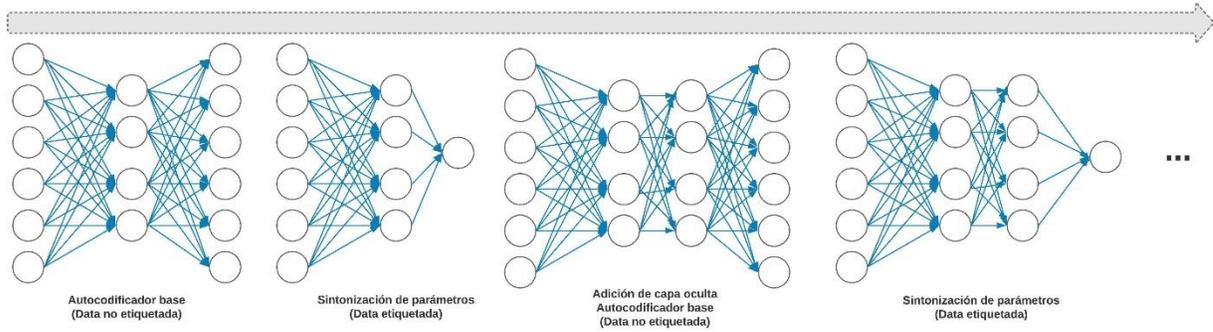


Figura 4.2.47. Arquitectura SAE Greedy layer-wise

Por otro lado, una alternativa similar es planteada por S. Rezaei en [205] donde emplea una Red Neuronal Convolutiva (CNN) en conjunto con una Red Neuronal Profunda (DNN); sin embargo, la arquitectura del modelo para ese escenario difiere completamente al contexto de los datos del perfil del servicio. En consecuencia, dicha alternativa ha sido adaptada de acuerdo con el perfil del usuario y haciendo uso de un algoritmo SAE con Greedy layer-wise en la parte superior de la arquitectura (ver Figura 4.2.48).

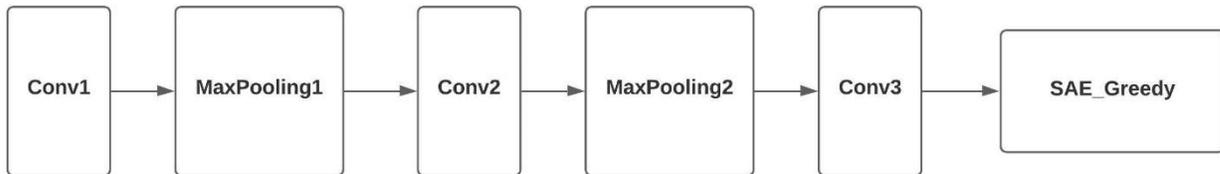


Figura 4.2.48. Arquitectura CNN con SAE Greedy layer-wise

Finalmente, se implementaron arquitecturas DNN y MLP fija con el ánimo de tener una comparación base dentro de las redes neuronales (ver figuras 4.2.49 y 4.2.50, respectivamente).

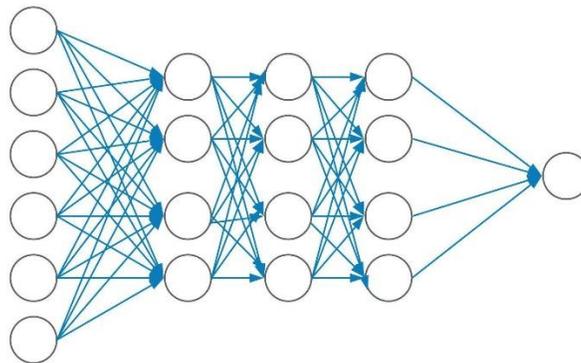


Figura 4.2.49. Arquitectura DNN implementada

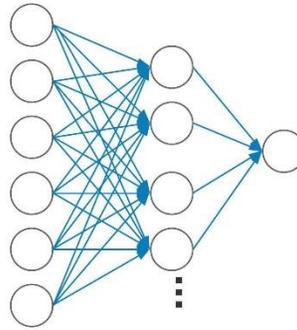


Figura 4.2.50. Arquitectura MLP implementada.

#### - Algoritmos de uso estandarizado

Estos algoritmos de regresión hacen parte del conjunto más utilizado de algoritmos implementados en diferentes escenarios donde se requiere predecir de manera supervisada una variable real o continua; esto es:

- Regresión lineal: Algoritmo que asume una distribución gaussiana en sus variables de entrada [193].
- Regresión Ridge: Algoritmo que parte de la regresión lineal, pero modificando la función de pérdida para minimizar la complejidad del modelo a través de la norma L2 [193].
- Regresión LASSO: Algoritmo que parte de la regresión lineal, pero modificando la función de pérdida para minimizar la complejidad del modelo a través de la norma L1 [193].
- Regresión de red elástica: Algoritmo de regresión de regularización que combina las propiedades tanto de Ridge como de LASSO [193].
- kNN de regresión: Algoritmo que localiza las  $k$  instancias más similares en el conjunto de datos en una nueva instancia [193].
- CART: Algoritmo que selecciona los mejores puntos para dividir los datos con el fin de minimizar la métrica de costo [193].
- SVR: Algoritmo que emplea la estrategia de vectores de soporte, pero en un contexto de regresión [193].

#### Parámetros iniciales

Los parámetros iniciales son aquellos valores de configuración de inicio para el entrenamiento de los modelos. Para los algoritmos seleccionados, se tiene:

#### - Redes neuronales

Para definir el número de capas escondidas en las estrategias de SAE-Greedy, y CNN con SAE-Greedy, se realiza una primera evaluación con un número  $n$  de niveles para observar el mejor comportamiento de acuerdo con la métrica seleccionada. La Figura 4.2.51, ilustra que para SAE-Greedy el número de capas escondidas con mejor desempeño es  $n=4$  (incluye el nivel de salida), y para CNN con SAE-Greedy el número de capas escondidas con mejor desempeño es  $n=11$  (incluye el nivel de salida y los niveles del patrón CNN). El mejor desempeño se establece por una menor diferencia entre la métrica MAE (Error Absoluto Medio) y MSE (Error Cuadrático Medio) para el conjunto de datos de entrenamiento y de prueba. La Figura 4.2.51 solo muestra los valores graficados de MAE



dimensión (ver Tabla 4.2.28). Finalmente, para el algoritmo MLP, se implementó la configuración por defecto [211] (Tabla 4.2.29), pero variando la función de optimización de los pesos (i.e. lbfgs, sgd, y adam).

Tabla 4.2.27. Estructura DNN fija implementada

Número de capas densas escondidas	Número de neuronas	Activación
3	256	Relu/lineal (capa salida)

Tabla 4.2.28. Estructura CNN fija implementada

	Conv1	MaxPoolin	Conv12	MaxPoolin	Conv3	DNN Fija
Número de filtros/neuronas	32	-	64	-	64	256
Tamaño kernel	3	2	2	2	3	-

Tabla 4.2.29. Estructura MLP implementada

Número de neuronas	Activación
100	Relu

- **Algoritmos de uso estandarizado**

Para estos algoritmos se fijó la configuración por defecto; esto es:

- LR con la configuración definida en [212]
- Ridge con configuración definida en [213]
- LASSO con configuración definida en [214]
- EN con configuración definida en [215]
- kNN de regresión con configuración definida en [216]
- CART con configuración definida en [217]
- SVR con configuración definida en [218]

**Identificador de configuración**

Las configuraciones propuestas para la evaluación de los algoritmos se basan en el empleo de la técnica de transformación de escalamiento de datos y en el número de descriptores empleados; esto es, para una transformación de normalización de datos, se pueden llevar a cabo dos estrategias. La primera, escoge el máximo y el mínimo para escalar los valores de los atributos (i.e. escalamiento por función de minimax [219]); la segunda, escala los valores por cada muestra del conjunto de datos a través de la norma L2 [201]. De igual manera, los descriptores que representan las calificaciones también fueron eliminados en algunas configuraciones de evaluación con el ánimo de verificar el desempeño de los algoritmos (e.g. q1, q2), y también debido a su alto grado de relación con la variable objetivo, lo cual podría afectar el desempeño de algunos algoritmos (e.g. regresión lineal).

Finalmente, se fijaron configuraciones como validación cruzada con 10 folds y selección de optimizadores dependiendo del tipo de algoritmo a evaluar.

Las tablas 4.2.30 a 4.2.34 presentan la configuración para cada identificador; los campos deben ser entendidos de la siguiente manera:

- Identificador de configuración: Corresponde al número de la configuración de la evaluación.
- Tipo de algoritmos: Representa el algoritmo a evaluar.
- Datos: Representa el subconjunto de datos utilizados de acuerdo al procedimiento implementado y la transformada aplicada.
- Características: Representa si incluye o no las características de tiempo y calificaciones parciales. Las características de tiempo agregan contexto de usuario (e.g. momento del día, de la semana), y las calificaciones parciales son aquellas valoraciones de la percepción de la calidad para cada uno de los servicios consumidos durante la sesión del usuario.
- Evaluación: Tipo de evaluación empleada en cada configuración. Para las estrategias que implementan el algoritmo Greedy, la validación cruzada no fue aplicada debido a la naturaleza iterativa del modelo donde se ajustan los parámetros de acuerdo con el subconjunto de datos no etiquetados

**Tabla 4.2.30.** Configuración de evaluación del algoritmo SAE-Greedy

Identificador	Algoritmo		Datos			Características		Evaluación
	Tipo	Parámetros no entrenables	Pre entrenamiento	Afinación	Transformada	Contexto de usuario	Calificaciones parciales	
A1	SAE-Greedy	Sí	No etiquetados	Etiquetados	Normalizer	Sí	Sí	-
B2	SAE-Greedy	No	No etiquetados	Etiquetados	Normalizer	Sí	Sí	-
C3	SAE-Greedy	Sí	No etiquetados	Etiquetados	Normalizer	Sí	No	-
D4	SAE-Greedy	No	No etiquetados	Etiquetados	Normalizer	Sí	No	-
E5	SAE-Greedy	Sí	No etiquetados	Etiquetados	Minmax	Sí	Sí	-
F6	SAE-Greedy	No	No etiquetados	Etiquetados	Minmax	Sí	Sí	-
G7	SAE-Greedy	Sí	No etiquetados	Etiquetados	Minmax	Sí	No	-
H8	SAE-Greedy	No	No etiquetados	Etiquetados	Minmax	Sí	No	-

**Tabla 4.2.31.** Configuración de evaluación del algoritmo SNN/SAE-Greedy

Identificador	Algoritmo		Datos			Características		Evaluación
	Tipo	Parámetros no entrenables	Pre entrenamiento	Afinación	Transformada	Contexto de usuario	Calificaciones parciales	
I9	CNN/SAE-Greedy	Sí	No etiquetados	Etiquetados	Normalizer	Sí	Sí	-
J10	CNN/SAE-Greedy	No	No etiquetados	Etiquetados	Normalizer	Sí	Sí	-
K11	CNN/SAE-Greedy	Sí	No etiquetados	Etiquetados	Normalizer	Sí	No	-
L12	CNN/SAE-Greedy	No	No etiquetados	Etiquetados	Normalizer	Sí	No	-
M13	CNN/SAE-Greedy	Sí	No etiquetados	Etiquetados	Minmax	Sí	Sí	-
N14	CNN/SAE-Greedy	No	No etiquetados	Etiquetados	Minmax	Sí	Sí	-
O15	CNN/SAE-Greedy	Sí	No etiquetados	Etiquetados	Minmax	Sí	No	-
P16	CNN/SAE-Greedy	No	No etiquetados	Etiquetados	Minmax	Sí	No	-

**Tabla 4.2.32.** Configuración de evaluación del algoritmo DNN/CNN

Identificador	Algoritmo		Datos			Características		Evaluación
	Tipo	Niveles fijos	Entrenamiento	Transformada	Contexto de usuario	Calificaciones parciales		
Q17	DNN	Sí	Etiquetado	Normalizer	Sí	Sí	Validación cruzada	
R18	DNN	Sí	Etiquetado	Normalizer	Sí	No	Validación cruzada	
S19	CNN	Sí	Etiquetado	Minmax	Sí	Sí	Validación cruzada	
T20	CNN	Sí	Etiquetado	Minmax	Sí	No	Validación cruzada	
U21	DNN	Sí	Etiquetado	Normalizer	Sí	Sí	Validación cruzada	
V22	DNN	Sí	Etiquetado	Normalizer	Sí	No	Validación cruzada	
W23	CNN	Sí	Etiquetado	Minmax	Sí	Sí	Validación cruzada	
X24	CNN	Sí	Etiquetado	Minmax	Sí	No	Validación cruzada	

**Tabla 4.2.33.** Configuración de evaluación del algoritmo MLP.

Identificador	Algoritmo		Datos		Características		Evaluación
	Tipo	Niveles fijos	Entrenamiento	Transformada	Contexto de usuario	Calificaciones parciales	
A1	MLP	Sí	Etiquetado	Normalizer	Sí	Sí	Validación cruzada
B2	MLP	Sí	Etiquetado	Normalizer	Sí	No	Validación cruzada
C3	MLP	Sí	Etiquetado	Minmax	Sí	Sí	Validación cruzada
D4	MLP	Sí	Etiquetado	Minmax	Sí	No	Validación cruzada

Tabla 4.2.34. Configuración de evaluación de los algoritmos de uso estandarizado.

Identificador	Algoritmo		Datos		Características		Evaluación
	Tipo	Niveles fijos	Entrenamiento	Transformada	Contexto de usuario	Calificaciones parciales	
A1	LR, Ridge, Lasso, EN, kNN, CART, SVR	Sí	Etiquetado	Normalizer	Sí	Sí	Validación cruzada
B2	LR, Ridge, Lasso, EN, kNN, CART, SVR	Sí	Etiquetado	Normalizer	Sí	No	Validación cruzada
C3	LR, Ridge, Lasso, EN, kNN, CART, SVR	Sí	Etiquetado	Minmax	Sí	Sí	Validación cruzada
D4	LR, Ridge, Lasso, EN, kNN, CART, SVR	Sí	Etiquetado	Minmax	Sí	No	Validación cruzada

### Métricas de evaluación

Para verificar el desempeño de los algoritmos seleccionados, se tuvieron en cuenta dos métricas para un problema de regresión. La primera, el Error Absoluto Medio (MAE), computa el error absoluto medio entre el valor de la variable conocida  $qt$  y el valor predicho  $\hat{qt}$ . La segunda, Error Cuadrático Medio (MSE), computa el error cuadrático medio entre el valor de la variable conocida  $qt$  y el valor predicho  $\hat{qt}$ . La métrica MAE da una idea de qué tan equivocadas estuvieron las predicciones (i.e. magnitud del error) [193]; mientras que la métrica MSE, penaliza en mayor medida la diferencia entre el valor verdadero y el predicho.

#### ➤ Generación y evaluación de los modelos

Los modelos generados a partir del entrenamiento con los datos de la percepción de la calidad debidamente preparados fueron evaluados de acuerdo con el diseño de comprobación. En consecuencia, para cada identificador, se tiene un resultado del error de acuerdo con las métricas definidas.

### Redes neuronales

Las figuras 4.2.52 y 4.2.53 presentan los resultados obtenidos. En ambas figuras las configuraciones definidas se mantienen, con la única diferencia que los resultados mostrados en la Figura 4.2.53 fueron alcanzados luego de aplicar una transformada de escalamiento a la variable objetivo (i.e. escalamiento de minimax para el descriptor  $qt$ ). En efecto, la transformación de la variable objetivo en problemas de regresión puede llegar a ser crítica para el desempeño de algunos algoritmos (e.g. redes neuronales) [198]. Los resultados de la Figura 4.2.53 presentan un mejor desempeño que aquellos algoritmos entrenados con una variable objetivo no escalada.

SAE-Greedy								
Métrica	A1	B2	C3	D4	E5	F6	G7	H8
Transformada: One-Hot, potencia, normalización (fit_unlabel_data)								
MAE	1,571	1,745	1,573	1,89	-	-	-	-
Transformada: One-Hot, potencia, MinMax (fit_unlabel_data)								
MAE	-	-	-	-	1,619	1,665	1,592	1,869

### CNN/SAE-Greedy

Métrica	I9	J10	K11	L12	M13	N14	O15	P16
Transformada: One-Hot; potencia, normalización (fit unlabel_data)								
MAE	1,581	3,148	1,572	3,366	-	-	-	-
Transformada: One-Hot; potencia, MinMax (fit unlabel_data)								
MAE	-	-	-	-	1,572	1,714	1,567	1,546

### DNN

Métrica	Q17	R18	S19	T20	U21	V22	W23	X24
Transformada: One-Hot; potencia, normalización (fit label_data)								
MAE	1,831	1,757	1,592	1,592	-	-	-	-
Transformada: One-Hot; potencia, MinMax (fit unlabel_data)								
MAE	-	-	-	-	1,871	1,794	1,602	1,625

### MLP

Métrica	A1			B2			C3			D4		
	lbfgs	sgd	adam									
Transformada: One-Hot; Potencia, normalización (fit data completa) - CV												
MAE	0,414	0,913	0,772	1,876	1,603	1,685	-	-	-	-	-	-
Transformada: One-Hot; Potencia, MinMax (fit data completa) - CV												
MAE	-	-	-	-	-	-	0,265	1,133	0,804	1,937	1,514	1,693

	Predicciones no variables
	Predicciones no válidas
	No Converge

Figura 4.2.52. Resultados MAE/MSE con algoritmos de redes neuronales – descriptor *qt* no transformado.

### SAE-Greedy

Métrica	A1	B2	C3	D4	E5	F6	G7	H8
Transformada: One-Hot; potencia, normalización (fit unlabel_data)								
MAE	0,299	0,342	0,301	0,33	-	-	-	-
MSE	0,11	0,152	0,11	0,139	-	-	-	-
Transformada: One-Hot; potencia, MinMax (fit unlabel_data)								
MAE	-	-	-	-	0,298	0,334	0,307	0,33
MSE	-	-	-	-	0,119	0,158	0,118	0,144

CNN/SAE-Greedy									
Métrica	I9	J10	K11	L12	M13	N14	O15	P16	
Transformada: One-Hot, potencia, normalización (fit_unlabel_data)									
MAE	0,299	0,345	0,301	0,326	-	-	-	-	
MSE	0,108	0,175	0,108	0,163	-	-	-	-	
Transformada: One-Hot, potencia, MinMax (fit_unlabel_data)									
MAE	-	-	-	-	0,305	0,332	0,297	0,346	
MSE	-	-	-	-	0,112	0,16	0,107	0,176	

DNN									
Métrica	Q17	R18	S19	T20	U21	V22	W23	X24	
Transformada: One-Hot, potencia, normalización (fit_unlabel_data)									
MAE	0,342	0,358	0,364	0,371	-	-	-	-	
MSE	0,162	0,168	0,184	0,186	-	-	-	-	
Transformada: One-Hot, potencia, MinMax (fit_unlabel_data)									
MAE	-	-	-	-	0,332	0,341	0,377	0,389	
MSE	-	-	-	-	0,152	0,158	0,209	0,221	

MLP													
Métrica	A1			B2			C3			D4			
	lbfgs	sgd	adam										
Transformada: One-Hot, Potencia, normalización (fit data completa) - CV													
MAE	0,424	1,291	0,828	1,838	1,616	1,722	-	-	-	-	-	-	-
MSE	0,295	2,044	0,986	4835	3,11	3,987	-	-	-	-	-	-	-
Transformada: One-Hot, Potencia, MinMax (fit data completa) - CV													
MAE	-	-	-	-	-	-	0,404	0,985	0,812	1,856	1,591	1,704	
MSE	-	-	-	-	-	-	0,284	1,37	0,949	5,098	3,283	3,936	

- Predicciones no variables
- Predicciones no válidas
- No Converge

**Figura 4.2.53.** Resultados MAE/MSE con algoritmos de redes neuronales – descriptor *qt* transformado.

Los algoritmos evaluados presentan buenos resultados para las métricas MAE y MSE; sin embargo, las predicciones de prueba que se realizaron sobre el subconjunto de datos no etiquetados con cada uno de los modelos, arrojan algunos resultados inconsistentes; esto es:

- Predicciones no variables: Predicciones que mantienen un cambio imperceptible del valor de *qt* (i.e. valor constante en la predicción), lo cual no corresponde con el comportamiento de la evaluación de la percepción de la calidad para el subconjunto de datos etiquetados.
- Predicciones no válidas: Predicciones negativas que no corresponden con el comportamiento de los datos de las sesiones calificadas.

Luego de analizar los resultados, las opciones con mejor desempeño fueron: SAE-Greedy con configuración G7, CNN/SAE-Greedy con configuración N14, DNN con configuración U21, y MLP con configuración C3-Adam. La selección tiene en cuenta los resultados donde el valor penalizado de la diferencia entre los valores reales y predichos es menor (i.e. MSE).

### Algoritmos de uso estandarizado

Las figuras 4.2.54 y 4.2.55 presentan los resultados obtenidos. En ambas figuras las configuraciones definidas se mantienen, con la única diferencia que los resultados mostrados en la Figura 4.2.55 fueron alcanzados luego de aplicar una transformada de escalamiento a la variable objetivo (i.e. escalamiento de minimax para el descriptor  $qt$ ); sin embargo, no hubo diferencias entre los dos conjuntos de resultados; es decir, la transformación de la variable  $qt$  no afecta el desempeño de los algoritmos evaluados (a excepción del algoritmo SVR).

LR				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,702	2,627	-	-
MSE	0,785	11,405	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,435	2,381
MSE	-	-	0,317	9,158

Ridge				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,479	1,688	-	-
MSE	0,372	3,695	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,311	1,809
MSE	-	-	0,171	4,323

Lasso				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	1,606	1,606	-	-
MSE	2,996	2,996	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	1,606	1,606
MSE	-	-	2,996	2,996

EN				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	1,606	1,606	-	-
MSE	2,996	2,996	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	1,468	1,606
MSE	-	-	2,504	2,996

kNN				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,861	1,708	-	-
MSE	1,17	3,915	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,868	1,691
MSE	-	-	1,116	3,739

CART				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,314	1,829	-	-
MSE	0,472	5,88	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,253	2,348
MSE	-	-	0,258	7,695

SVR				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	1,517	1,602	-	-
MSE	2,917	3,291	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	1,332	1,604
MSE	-	-	2,217	3,308

 Predicciones no variables

 Predicciones no válidas

Figura 4.2.54. Resultados MAE/MSE con algoritmos estandarizados – descriptor *qt* no transformado

LR				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,703	2,629	-	-
MSE	0,784	11,416	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,435	2,382
MSE	-	-	0,318	9,161

Ridge				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,479	1,689	-	-
MSE	0,372	3,695	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,311	1,809
MSE	-	-	0,171	4,323

Lasso				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	1,606	1,606	-	-
MSE	2,996	2,996	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	1,606	1,606
MSE	-	-	2,996	2,996

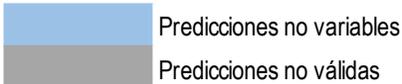
EN				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	1,606	1,606	-	-
MSE	2,996	2,996	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	1,606	1,606
MSE	-	-	2,996	2,996

kNN				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,861	1,708	-	-
MSE	1,17	3,915	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,868	1,691
MSE	-	-	1,116	3,739

CART				
Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	0,333	1,938	-	-
MSE	0,362	6,239	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,239	2,298
MSE	-	-	0,258	7,476

**SVR**

Métrica	A1	B2	C3	D4
Transformada: One-Hot, Power - Normalizer (fit data completa)				
MAE	1,266	1,598	-	-
MSE	1,983	3,244	-	-
Transformada: One-Hot, Power Minmax (fit data completa)				
MAE	-	-	0,68	1,602
MSE	-	-	0,674	3,301



**Figura 4.2.55.** Resultados MAE/MSE con algoritmos estandarizados – descriptor *qt* transformado.

Al igual que en el caso de los algoritmos de redes neuronales, algunos presentan inconsistencias en las predicciones para el subconjunto de datos no etiquetados; es decir, hay presencia de predicciones no variables y predicciones no válidas. En consecuencia, el algoritmo con mejor desempeño es el algoritmo Ridge con configuración A1.

Finalmente, la elección del modelo para la implementación del bloque semisupervisado se realiza a partir de la comparación entre el comportamiento de la variable *qt* para el subconjunto de datos etiquetado y el conjunto de datos que han sido predichos; es decir, se compara la distribución de los datos de la variable *qt* en términos de la distancia entre las distribuciones de los datos para los subconjuntos de datos etiquetados y predichos con dimensiones (114, 13) y (1.142, 13), respectivamente. Para ello, se aplicó la prueba de Kolmogorov-Smirnov [220][221] (Tabla 4.2.35).

**Tabla 4.2.35.** Comparación de distribución de datos base y predichos por algoritmo – Prueba Kolmogorov-Smirnov

Datos de base (114, 13)	Datos predichos (1142, 13)									
	Rigde		MLP		SAE		CNN/SAE		DNN	
	Estadístico	valor-p	Estadístico	valor-p	Estadístico	valor-p	Estadístico	valor-p	Estadístico	valor-p
	0,336	6,195E-11	0,502	1,44E-15	0,406	1,78E-15	0,474	1,44E-15	0,591	1,44E-15

Estadístico: Valor absoluto más grande de la diferencia entre dos funciones de distribuciones en todos los valores de x

Para la prueba de Kolmogorov-Smirnov, la hipótesis nula por defecto que se tiene es que las dos distribuciones del conjunto de datos son idénticas. En ese sentido, para todas las predicciones realizadas por los algoritmos, los resultados muestran que son estadísticamente significativos para rechazar la hipótesis (valor-p por debajo del nivel de significancia 1%). Adicionalmente, el estadístico para cada conjunto de datos predichos indica qué tan alejada es una distribución en relación con la distribución de los datos de base. En ese sentido, el algoritmo Ridge presenta el menor valor estadístico para todo el conjunto de datos predichos.

### iii. Bloque Entrenamiento del modelo

Este bloque (Figura 4.2.45) se encarga de entrenar el modelo con el mejor desempeño en las predicciones de valor *qt* de acuerdo con los criterios establecidos en el bloque de Evaluación de algoritmos. El entrenamiento del modelo se realiza a partir del subconjunto de datos etiquetados. Al final, un modelo Ridge predice el valor de la percepción de la calidad a partir del comportamiento de consumo del usuario.

#### iv. Bloque Semi\_supervisado

Los métodos semisupervisados consisten en usar tanto datos etiquetados como no etiquetados para realizar cierta tarea específica [206]. En particular, los métodos de envoltura y de procesamiento previo sin supervisión son los más empleados [206].

En los métodos de envoltura, un modelo es entrenado primeramente con los datos etiquetados disponibles, y luego reentrenado con los datos que se predicen y los datos etiquetados. Utilizando este método, y de acuerdo con los resultados obtenidos en la evaluación de los algoritmos, se presenta el esquema semisupervisado implementado para el perfil de usuario (ver Figura 4.2.56). Es importante resaltar que se implementó el método de procesamiento previo sin supervisión, pero no se obtuvieron unos resultados confiables (ver sección 4.2.3.3 literal A índice ii).

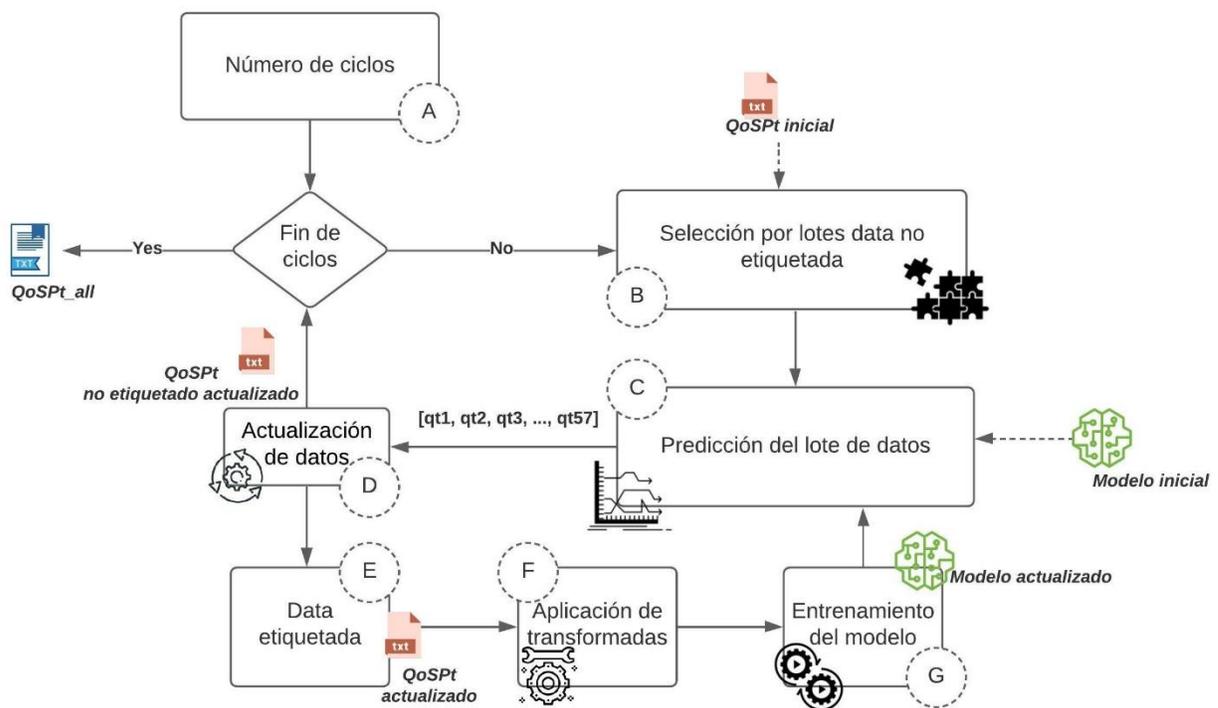


Figura 4.2.56. Esquema semisupervisado para el perfil de usuario.

El método de envoltura parte de la determinación del número de ciclos que se repetirá el proceso de entrenamiento semisupervisado (A). Posteriormente, los datos de percepción de calidad no etiquetados son seleccionados por lotes de manera aleatoria para que el modelo inicial realice la predicción del valor  $qt$  (B y C, respectivamente). Las predicciones de cada lote de datos (i.e. pseudo-etiquetas) son agregadas a cada una de las sesiones respectivas (D). Finalmente, los datos actualizados con las nuevas sesiones etiquetadas son preparados con las transformadas definidas y utilizados para entrenar nuevamente el modelo de predicción (E, F, y G, respectivamente). Al final, se obtiene un conjunto de datos totalmente etiquetado para todas las sesiones de consumo de servicios OTT del usuario (i.e. QoSPt\_all).

#### B. Componente estimación – perfil paramétrico

Luego de la preparación de los datos del perfil paramétrico, estos son entregados a los tres bloques desarrollados para la implementación del componente (ver Figura 4.2.57). El primero, *Selección de algoritmos*,

realiza una elección de algoritmos de uso general de acuerdo con el problema de aprendizaje automático detectado (i.e. problema de regresión); el segundo, *Evaluación de algoritmos*, determina el diseño de comprobación, el esquema de entrenamiento, y verifica la calidad de un conjunto de algoritmos de aprendizaje automático de uso estandarizado. Finalmente, *Entrenamiento del modelo*, realiza el entrenamiento del modelo con el algoritmo de mejor desempeño y con los datos del perfil paramétrico debidamente estructurados. Al final, se obtiene un modelo de estimación de la percepción de la calidad para determinar, a partir del comportamiento de tráfico obtenido mediante el protocolo Netflow, la evaluación general de la percepción de la calidad de los usuarios luego de consumir servicios OTT.

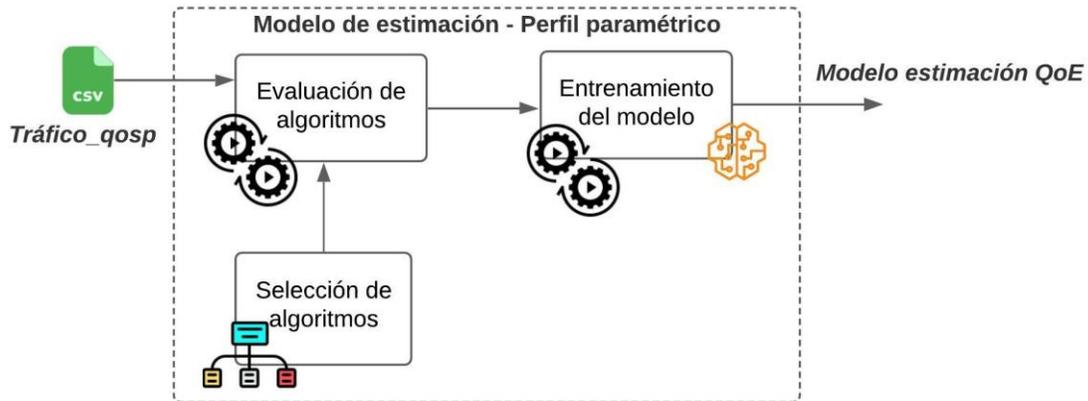


Figura 4.2.57. Componente estimación – perfil paramétrico (Módulo Modelado)

La Tabla 4.2.36. presenta la implementación de tareas generales CRISP-DM en los bloques del Componente estimación para el perfil paramétrico.

Tabla 4.2.36. Implementación de tareas CRISP-DM en el Componente estimación del perfil paramétrico

Componente estimación – perfil paramétrico.	Tareas CRISP-DM
Selección de algoritmos	Selección de técnicas de modelado
Evaluación de algoritmos	Generación de un diseño de comprobación, generación de modelos, y evaluación del modelo

**i. Bloque Selección de algoritmos**

La elección de los algoritmos parte del análisis de los datos del perfil paramétrico, donde la variable a predecir indica un problema de regresión. En consecuencia, los algoritmos a evaluar son aquellos analizados para el perfil de usuario en la Tabla 4.2.22 (ver sección 4.2.3.3 literal A índice i). En este caso, solo se considera el algoritmo MLP como base de comparación para las redes neuronales; los otros algoritmos no fueron seleccionados ya que no se cuenta con una alta dimensionalidad del conjunto de datos.

**ii. Bloque Evaluación de algoritmos**

➤ **Diseño de comprobación**

Para la evaluación de los algoritmos de aprendizaje automático seleccionados, se definió un esquema de comprobación con el ánimo de medir la calidad y validez de cada uno de los modelos; esto es (Tabla 4.2.37):

- Algoritmos de modelado perfil de paramétrico: Presenta las opciones de los algoritmos candidatos en la estimación del descriptor  $qt$  del perfil del usuario.
- Parámetros iniciales: Define los parámetros iniciales de configuración para cada uno de los algoritmos.
- Identificador de configuración de evaluación: Presenta el identificador de la configuración de las pruebas de acuerdo con las técnicas de preparación usadas
- Métrica de evaluación: Métrica usada para evaluar el desempeño de los algoritmos en relación con la predicción del descriptor  $qt$ .

**Tabla 4.2.37.** Diseño de comprobación

Algoritmos de modelado perfil paramétrico		Parámetros iniciales	Identificador de configuración	Métrica de evaluación
<b>Redes Nueronales (NN)</b>	MLP	Hiperparámetros por defecto	A1, B2, C3, D4	MAE/MSE
	Regresión lineal	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
	Regresión Ridge	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
	Regresión lineal LASSO	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
<b>Algoritmos de uso estandarizado</b>	Regresión neta elástica - EN	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
	kNN	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
	CART	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE
	SVR	Parámetros por defecto	A1, B2, C3, D4	MAE/MSE

Para los campos Algoritmos de modelado, parámetros iniciales, y métrica de evaluación, las descripciones son las mismas que las presentadas en el perfil de usuario (ver sección 4.2.3.3 literal A índice ii).

### Identificador de configuración

Las configuraciones propuestas para la evaluación de los algoritmos se basan en el empleo de la técnica de transformación modificación gaussiana; esto es, para la transformación gaussiana se pueden llevar a cabo dos estrategias. La primera, una modificación de la distribución de los datos a un comportamiento normal; la segunda, una modificación de la distribución de los datos a un comportamiento uniforme.

Finalmente, se fijaron configuraciones como validación cruzada con 10 folds y selección de optimizadores dependiendo del tipo de algoritmo a evaluar.

Las tablas 4.2.38 y 4.2.39 presentan la configuración para cada identificador; los campos deben ser entendidos de la siguiente manera:

- Identificador de configuración: Corresponde al número de la configuración de la evaluación.
- Tipo de algoritmos: Representa el algoritmo a evaluar.
- Datos: Representa el subconjunto de datos utilizados de acuerdo al procedimiento implementado y la transformada aplicada.
- Características: Representa si incluye o no las características de tiempo. Las características de tiempo agregan contexto de usuario (e.g. momento del día, de la semana).
- Evaluación: Tipo de evaluación empleada en cada configuración.

Tabla 4.2.38. Configuración de evaluación del algoritmo MLP.

Identificador	Algoritmo	Datos		Evaluación
		Entrenamiento	Transformada	
A1	MLP	Etiquetado	Imputación, normalizer, gauss_normal	Validación cruzada
B2	MLP	Etiquetado	Imputación, normalizer, gauss_uniform	Validación cruzada
C3	MLP	Etiquetado	Imputación, gauss_normal, normalizer	Validación cruzada
D4	MLP	Etiquetado	Imputación, gauss_uniform, normalizer	Validación cruzada

Tabla 4.2.39. Configuración de evaluación de los algoritmos de uso estandarizado.

Identificador	Algoritmo	Datos		Evaluación
		Entrenamiento	Transformada	
A1	LR, Ridge, Lasso, EN, kNN, CART	Etiquetado	Imputación, normalizer, gauss_normal	Validación cruzada
B2	LR, Ridge, Lasso, EN, kNN, CART	Etiquetado	Imputación, normalizer, gauss_uniform	Validación cruzada
C3	LR, Ridge, Lasso, EN, kNN, CART	Etiquetado	Imputación, gauss_normal, normalizer	Validación cruzada
D4	LR, Ridge, Lasso, EN, kNN, CART	Etiquetado	Imputación, gauss_uniform, normalizer	Validación cruzada

### ➤ Generación y evaluación de los modelos

Los modelos generados a partir del entrenamiento con los datos del perfil paramétrico debidamente preparados fueron evaluados de acuerdo con el diseño de comprobación. En consecuencia, para cada identificador, se tiene un resultado del error de acuerdo con las métricas definidas.

### Redes neuronales

La Figura 4.2.58 presenta los resultados obtenidos para el algoritmo MLP. Al final, la configuración C3-Adam presenta el menor valor de penalización entre el valor real y predicho (i.e. MSE). Para el optimizador lbfgs, en todas las configuraciones, el algoritmo MLP no converge.

Métrica	MLP											
	A1			B2			C3			D4		
	lbfgs	sgd	adam									
Transformada: miss_imputer, normalizer, gauss_normal/uniform												
MAE	nc	0,527	0,428	nc	0,538	0,441	-	-	-	-	-	-
MSE	nc	0,487	0,325	nc	0,504	0,347	-	-	-	-	-	-
Transformada: miss_imputer, gauss_normal/uniform, normalizer												
MAE	-	-	-	-	-	-	nc	0,506	0,299	nc	0,509	0,344
MSE	-	-	-	-	-	-	nc	0,441	0,167	nc	0,457	0,215

 Opción seleccionada  
 No converge

Figura 4.2.58. Resultados MAE/MSE con algoritmos MLP – descriptor *qt* transformado

### Algoritmos de uso estandarizado

Las Figura 4.2.59 presenta los resultados obtenidos. Al final, la configuración C3 para el algoritmo CART presenta el menor valor de penalización entre el valores reales y predichos (i.e. MSE).

LR					Ridge				
Métrica	A1	B2	C3	D4	Métrica	A1	B2	C3	D4
Transformada: miss_imputer, normalizer, gauss_normal/uniform					Transformada: miss_imputer, normalizer, gauss_normal/uniform				
MAE	0,569	0,558	-	-	MAE	0,569	0,558	-	-
MSE	0,553	0,539	-	-	MSE	0,553	0,539	-	-
Transformada: miss_imputer, gauss_normal/uniform, normalizer					Transformada: miss_imputer, gauss_normal/uniform, normalizer				
MAE	-	-	0,523	0,517	MAE	-	-	0,524	0,518
MSE	-	-	0,479	0,458	MSE	-	-	0,479	0,461

Lasso					EN				
Métrica	A1	B2	C3	D4	Métrica	A1	B2	C3	D4
Transformada: miss_imputer, normalizer, gauss_normal/uniform					Transformada: miss_imputer, normalizer, gauss_normal/uniform				
MAE	0,697	0,697	-	-	MAE	0,697	0,697	-	-
MSE	0,775	0,775	-	-	MSE	0,775	0,775	-	-
Transformada: miss_imputer, gauss_normal/uniform, normalizer					Transformada: miss_imputer, gauss_normal/uniform, normalizer				
MAE	-	-	0,697	0,697	MAE	-	-	0,697	0,697
MSE	-	-	0,775	0,775	MSE	-	-	0,775	0,775

kNN					CART				
Métrica	A1	B2	C3	D4	Métrica	A1	B2	C3	D4
Transformada: miss_imputer, normalizer, gauss_normal/uniform					Transformada: miss_imputer, normalizer, gauss_normal/uniform				
MAE	0,339	0,324	-	-	MAE	0,232	0,235	-	-
MSE	0,267	0,249	-	-	MSE	0,202	0,206	-	-
Transformada: miss_imputer, gauss_normal/uniform, normalizer					Transformada: miss_imputer, gauss_normal/uniform, normalizer				
MAE	-	-	0,228	0,224	MAE	-	-	0,123	0,128
MSE	-	-	0,145	0,137	MSE	-	-	0,057	0,063

 Opción seleccionada

Figura 4.2.59. Resultados MAE/MSE con algoritmos estandarizados – descriptor *qt* transformado

### iii. Bloque Entrenamiento del modelo

Este bloque se encarga de entrenar el modelo con el mejor desempeño en las predicciones de valor *qt* de acuerdo con los criterios establecidos en el bloque de Evaluación de algoritmos. Lo anterior se conoce como finalización del modelo de acuerdo con las etapas de un proyecto de aprendizaje automático [193]. Adicionalmente, el entrenamiento del modelo se realiza a partir el subconjunto de datos etiquetados de tráfico del perfil paramétrico. Al final, un modelo CART (opción C3) predice el valor de la QoE a partir del comportamiento del tráfico de la red en el aprovisionamiento de servicios OTT.

#### 4.2.4. Explotación o despliegue del modelo correlacional QoS-QoE

La Figura 4.2.60 presenta el diagrama de despliegue o de explotación del modelo correlacional QoS-QoE para el aprovisionamiento de servicios OTT. El diagrama se define de acuerdo con la finalidad del modelo expuesto en la sección 4.2.2., donde el modelo construido de la estimación de la QoE, en la fase de creación, es explotado dentro del módulo de Monitorización QoE en su componente de Estimación QoE

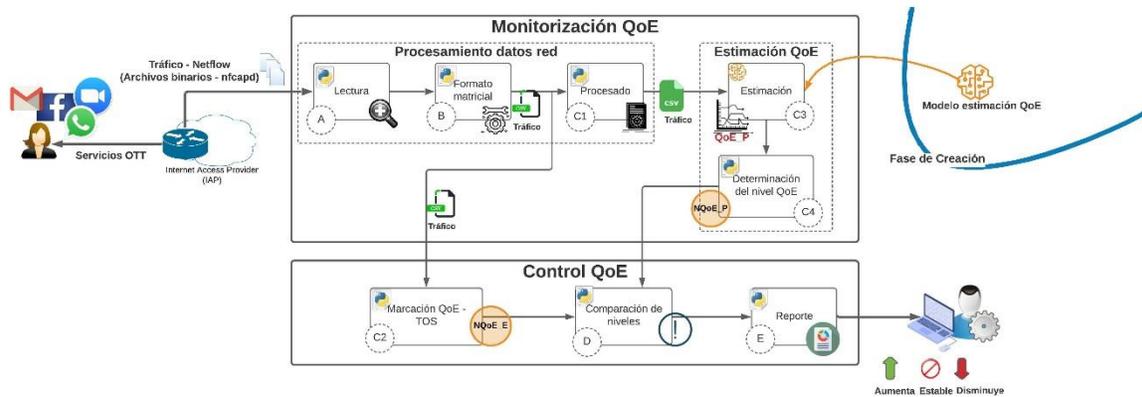


Figura 4.2.60. Diagrama de explotación del modelo correlacional QoS-QoE – Sistema de Gestión QoE

Una vez el modelo correlacional ha sido estructurado de acuerdo con los datos recolectados (i.e. construcción del modelo de correlación, sección 4.2.3), este es desplegado en la infraestructura de la Telco con el ánimo de estimar el nivel de QoE de sus usuarios luego de consumir sus servicios. Los tiempos de monitorización del tráfico por medio del protocolo Netflow deben ser definidos por la Telco con base en los requisitos específicos que este tenga (e.g. periodos diarios, semanales, quincenales o mensuales). Los archivos binarios recolectados por el nodo de recolección (i.e. enrutador) son enviados al sistema de gestión de la QoE propuesto.

El sistema de explotación del modelo correlacional QoS-QoE, o de gestión de la QoE, está conformado por dos módulos. El primero, *Monitorización QoE*, recolecta la información de los archivos binarios Netflow y estima los niveles de QoE para el grupo de usuarios monitorizados. El segundo, *Control QoE*, verifica y compara los niveles de QoE que se estiman y los esperados por la Telco dentro de su red de aprovisionamiento de servicios.

##### 4.2.4.1. Módulo Monitorización QoE

Este módulo recibe los archivos binarios Netflow generados en el nodo de recolección de tráfico (i.e. enrutador) y estima un nivel de QoE para cada usuario que haya sido objeto de monitorización. Sin embargo, antes de realizar la estimación del nivel QoE, los datos binarios deben ser adaptados a la estructura requerida por el componente de estimación. En ese sentido, se tiene lo siguiente:

En el componente *Procesamiento datos red*, el bloque de *Lectura* (A) ejecuta los archivos de comandos desarrollados para obtener los descriptores válidos y sus valores a partir de los datos binarios de entrada. Estos descriptores válidos describen el comportamiento de consumo de los usuarios (e.g. paquetes, bps, flujos, direcciones IP origen-destino) y las condiciones de QoS configuradas en el nodo de recolección (i.e. descriptor tos).

El bloque de *Formato Matricial* (B) estructura el lote de datos recolectados en un formato de matriz, y define con claridad los tipos de datos para cada descriptor de tráfico. En este componente solo se tiene en cuenta el

tráfico recolectado y no los datos de percepción del usuario; estos últimos solo son usados para estructurar y crear el modelo de estimación o para actualizar el modelo de acuerdo con futuros comportamientos de consumo o cambios técnicos en la infraestructura de aprovisionamiento de servicios.

El bloque *Procesado* (C1) ejecuta los archivos de comandos de las transformaciones definidas para el tratamiento de los datos de tráfico en contexto con el ánimo de ajustar cada descriptor a lo requerido por el modelo de estimación. Las transformaciones ejecutadas son aquellas empleadas en la fase de creación con los mejores resultados.

Por su parte, el componente de *Estimación QoE* (C3-C4) recibe los datos de los descriptores de tráfico para cada usuario y estima el nivel de la QoE para cada uno de ellos. Para ello, el bloque *Determinación de nivel QoE* convierte el valor numérico estimado por el bloque *Estimación* en una categoría subjetiva MOS (i.e. el valor QoE\_P (QoE Predicho) se convierte en una categoría NQoE\_P). La Figura 4.2.61 presenta la conversión numérica de la escala absoluta MOS en una categoría subjetiva MOS. Los rangos definidos para la conversión fueron adaptados de [222].

**QoE\_P ---> NQoE\_P (MOS)**

0 <= QoE_P <= 1.5	---->	<b>MALA</b>
1.5 < QoE_P <= 2.5	---->	<b>MEDIOCRE</b>
2.5 < QoE_P <= 3.5	---->	<b>REGULAR</b>
3.5 < QoE_P <= 4.5	---->	<b>BUENA</b>
4.5 < QoE_P <= 5.0	---->	<b>EXCELENTE</b>

**Figura 4.2.61.** Mapa de conversión de la escala absoluta MOS en categoría subjetiva MOS

**4.2.4.2. Módulo Control QoE**

Este módulo recibe el archivo estructurado de tráfico y marca cada flujo con un nivel de QoE esperado por la Telco de acuerdo con la QoS configurada en el nodo de recolección (i.e. enrutador); esto es:

El componente de *Marcación QoE – TOS* etiqueta cada flujo bidireccional del conjunto de datos estructurado de tráfico, de acuerdo con el valor del descriptor *tos* para cada flujo bidireccional identificado. La QoS configurada en el nodo de recolección permite que el tráfico clasificado en una *clase de servicio* específica, reciba un tratamiento diferenciado para mitigar el efecto de la velocidad de transmisión, pérdida de paquetes, latencia o *jitter*. Estas variables producen un efecto negativo sobre la calidad del servicio en presencia de la congestión del canal. En ese sentido, la QoS gestiona, a través de sus métodos de enrutamiento, la prioridad de tratamiento que recibirán los flujos de acuerdo con la clase en la que estos han sido clasificados. La clasificación de los flujos se realiza a partir de políticas establecidas y de algoritmos propios del nodo de enrutamiento. Una vez los flujos son clasificados en alguna clase, los paquetes que pertenecen al mismo flujo (i.e. IP origen – destino, puertos origen – destino, protocolo de conexión) son marcados con el ánimo de ser interpretados por los siguientes nodos de la red por los que vayan a transitar los paquetes cuando salgan del nodo de recolección. Esta marca es el descriptor *tos* asignado a cada flujo bidireccional para una conexión usuario – servicio.

En este componente, la Telco asigna un nivel esperado de la QoE a cada flujo (i.e. NQoE\_E), en concordancia con la marca *tos*, y más exactamente, el código DSCP del campo DS (Figura 4.2.7). La política de marcación de la Telco permite establecer un umbral mínimo para que cada flujo bidireccional reciba los recursos necesarios para mantener el nivel de QoS sin que la QoE se vea perjudicada; e.g., un valor de *Tos* = 0 para los flujos bidireccionales clasificados en alguna clase de servicio específica, podría ser asignado a un nivel de QoE Regular por parte de la Telco, mientras que para otros valores de *tos*, la asignación del nivel de QoE puede ser

superior (e.g. Buena, Excelente). Este nivel de QoE es el que espera la Telco obtener cuando para dicho flujo bidireccional se tenga una marca de *tos* específica, y por ende, una QoS determinada dentro de la red.

El componente de *Comparación de niveles* realiza un contraste entre el nivel QoE predicho (i.e. NQoE\_P), entregado por el componente de Estimación QoE del módulo Monitorización QoE, y el Nivel QoE esperado (i.e. NQoE\_E) para cada uno de los flujos bidireccionales de las conexiones Usuario – Servicio; dicha comparación genera una etiqueta que describe si el nivel QoE predicho se mantiene, es inferior o superior al nivel QoE esperado.

El componente de *Reporte* genera una bandera de notificación cuando se tenga un nivel estimado de QoE inferior al nivel esperado de QoE. Esta bandera notifica al operador de red para que analice el caso específico y realice las configuraciones en el nodo de recolección que le correspondan.

#### 4.2.5. Ejemplo de funcionamiento del modelo correlacional QoS-QoE

A manera de ejemplo, se presenta a continuación un escenario del sistema de gestión de la QoE haciendo uso de los datos de tráfico recolectados que no han sido etiquetados con el descriptor *qt*, es decir, un conjunto de datos de flujos bidireccionales con dimensión (4.836.581,16). Lo anterior implica que los bloques de Lectura y Formato matricial fueron ejecutados de manera previa. En ese sentido, el proceso da inicio a la salida del bloque de Formato matricial (B).

Un conjunto de usuarios consume diferentes servicios OTT dentro de la infraestructura del operador y genera un alto tráfico al terminar el periodo de monitorización de la QoE definido dentro de las políticas de gestión. Este tráfico es recolectado por el enrutador de frontera a través del protocolo Netflow y registrado en archivos binarios dentro de un repositorio. El sistema de gestión de la QoE, una vez finalizado el periodo de monitorización (e.g. un día, una semana), realiza la lectura y la estructuración matricial de los archivos binarios (e.g. flujos bidireccionales con la dimensión de 4.836.581 registros y 16 descriptores).

Los datos estructurados son divididos por lotes con el ánimo de realizar el control de la QoE y así reducir la carga de procesamiento que se pueda generar al momento de analizar todos los datos recolectados. En consecuencia, se seleccionan lotes aleatorios de 100 registros para realizar la comparación de los niveles de la QoE predicha y la QoE esperada por el operador.

Para la QoE predicha (i.e. QoE\_P), el procesado de los datos para un lote aleatorio de 100 registros presenta los resultados mostrados en la Figura 4.2.62.

```
-->Duplicados: False                                     -->Detección de valores atípicos con estrategia Local Outlier Factor - LOF
--OUTPUT
DataSet_lof: (79, 16) - Registros eliminados: 21 - form: [['2019-04-18 11:34:49.814' '2019-04-18 11:34:50.064' 0.25 '185.53.91.24'
'163.117.142.115' 57432 5038.0 6 40 1 42 1 42 4 1344 0.0]
['2018-12-31 18:22:36.522' '2018-12-31 18:22:36.672' 0.15
'104.196.50.168' '163.117.142.218' 53763 5068.0 6 0 1 42 1 42 6 2240
0.0]]

a. Duplicados                                          b. Valores atípicos – LOF
-->Cantidad de valores perdidos 0 valor:              NOTA: No se convierte a NaN attr-tos/qt por ser un comportamiento válido
-->Cantidad de valores NaN - %Total - iteration method
ts, Missing: 0 (0.0%)
te, Missing: 0 (0.0%) |
td, Missing: 6 (7.6%) |
sa, Missing: 0 (0.0%) |
da, Missing: 0 (0.0%) |
sp, Missing: 0 (0.0%) |
dp, Missing: 0 (0.0%) |
pr, Missing: 0 (0.0%) |
pkt, Missing: 0 (0.0%) |
byt, Missing: 0 (0.0%) |
fl, Missing: 0 (0.0%) |
bpp, Missing: 0 (0.0%) |
pps, Missing: 25 (31.6%) |
bps, Missing: 6 (7.6%) |
--OUTPUT:
DataSet_miss: (73, 16) - Registros eliminados: 6

ts      0
te      0
td      6
sa      0
da      0
sp      0
dp      0
pr      0
tos     53
pkt     0
byt     0
fl      0
bpp     0
pps     25
bps     6
qt      79
dtype: int64
```

#### c. Valores perdidos

```
(73, 31) Index(['ts', 'te', 'td', 'sa', 'da', 'sp', 'dp', 'pr', 'pkt', 'byt', 'fl',
              'bpp', 'pps', 'bps', 'tos', 'qt', 'mm_on', 'dd_on', 'hh_on', 'min_on',
              'sec_on', 'w_on', 'wd_on', 'mm_off', 'dd_off', 'hh_off', 'min_off',
              'sec_off', 'w_off', 'wd_off', 'nQoE_P'],
              dtype='object')
```

d. Datos tráfico preparado

Figura 4.2.62. Reporte de resultados de preparación (Monitorización – preparación)

En la Figura 4.2.62, los 100 registros seleccionados de manera aleatoria no presentan observaciones duplicadas que resulten redundantes para el componente de Estimación QoE (a), pero sí hay observaciones que presentan valores atípicos (b) y mediciones incorrectas (c). En consecuencia, se tienen 0 registros eliminados por observaciones duplicadas, 21 registros eliminados por valores atípicos, y 6 registros eliminados por medición incorrecta donde la duración del flujo es cero ( $td = 0$ ).

Finalmente, los 73 registros son transformados de acuerdo con las funciones implementadas por el bloque de Procesado de la Figura 4.2.60; como resultado, se tienen 31 características, siendo la variable  $nQoE\_P$  el nivel de la QoE en categoría MOS que corresponde al valor predicho en  $qt$  (d). Tanto  $qt$  como  $nQoE\_P$  son inicializados con un valor de cero dentro de este bloque.

Posteriormente, la  $QoE\_P$  es transformada a una categoría MOS de acuerdo con los rangos definidos en la Figura 4.2.61. En consecuencia, se tiene (ver Figura 4.2.63):

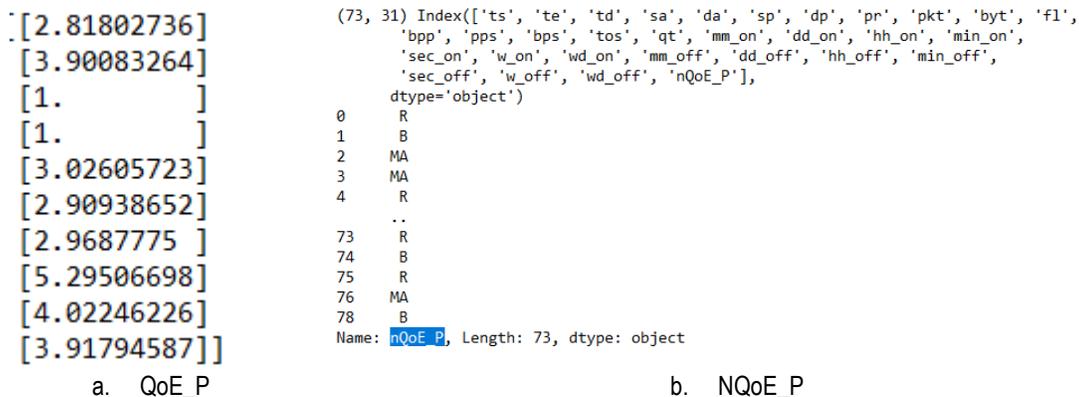


Figura 4.2.63. NQoE\_P para un lote de datos de tráfico (Monitorización - Predicción)

En la Figura 4.2.63 se muestran 10 valores predichos para la QoE representados por el descriptor  $qt$  (a) y las categorías MOS de la QoE para la totalidad de los 73 registros (b; donde B=Buena, R=Regular, MA=Mala), representadas por el descriptor  $nQoE\_P$ . El valor estimado por encima del límite superior para el descriptor  $qt$  es producto del valor MAE del algoritmo entrenado en la fase de modelado, que posteriormente es adaptado de acuerdo con los rangos definidos en la Figura 4.2.61

Por otra parte, para el nivel de QoE esperada (i.e.  $NQoE\_E$ ), los registros aleatorios seleccionados son transformados a una categoría MOS de acuerdo con el descriptor  $tos$  en cada flujo bidireccional y con el nivel esperado de la QoE en cada una de las clases de servicio definidas por el operador. En este caso, las clases de servicio de referencia son aquellas definidas por la configuración del campo DSCP del paquete IPv4 (i.e.

RFC-4594). La Tabla 4.2.40 presenta la NQoE\_E para cada clase de servicio de acuerdo con las políticas establecidas por la Telco en este escenario de ejemplo.

**Tabla 4.2.40.** Conversión DSCP a categoría MOS por políticas de QoS.

<b>Campo de servicios diferenciado, RFC-2474 [223]</b>			<b>Nivel de QoE esperado por la Telco (NQoE_E)</b>
<i>Clase de servicio de usuario RFC-4594 [183]</i>	<i>Código DSCP</i>	<i>Valor decimal – IANA [224]</i>	
Telefonía	EF	46	Excelente
Conferencia multimedia	AF41 AF42 AF43	34, 36, 38, respectivamente	Excelente
Tiempo real interactivo	CS4	32	Excelente
Streaming Multimedia	AF31 AF32 AF33	26, 28, 30, respectivamente	Buena
Video Broadcast	CS3	24	Buena
Datos de baja latencia	AF21 AF22 AF23	18, 20, 22, respectivamente	Regular
Datos de alta velocidad	AF11 AF12 AF13	10, 12, 14, respectivamente	Buena
Datos de baja prioridad	CS1	8	Regular
Estándar	DF o CS0	0	Regular

Para la Tabla 4.2.40, se ha simulado la política de aprovisionamiento de QoE para cada una de las clases de servicio de usuario, de la siguiente manera:

- Servicios con alta demanda de recursos se espera que tengan un nivel de QoE *Excelente*.
- Servicios con demanda media de recursos se espera que tengan un nivel de QoE *Buena*.
- Servicios con baja demanda de recursos se espera que tengan un nivel de QoE *Regular*

Para realizar la conversión de acuerdo con la Tabla 4.2.40, el valor del descriptor *tos* en decimal debe ser trasladado previamente al valor del código DSCP en decimal, teniendo en cuenta que los 6 bits más significativos de *tos* corresponden a DSCP; luego, se realiza la marcación de la categoría MOS (NQoE\_E) de acuerdo con las políticas de aprovisionamiento QoE establecidas por el operador (ver Tabla 4.2.41).

**Tabla 4.2.41.** Conversión valor decimal *tos* a categoría MOS

<b>Descriptor <i>tos</i> en decimal</b>	<b>Código DSCP en decimal</b>	<b>Categoría MOS (NQoE_E)</b>
184,	46,	Excelente (E)
136, 144, 152,	34, 36, 38,	
128	32	
104, 112, 120	26, 28, 30,	Buena (B)
96,	24,	
40, 48, 56	10, 12, 14	
72, 80, 88,	18, 20, 22,	Regular (R)
32,	8,	
0	0	

Al final, se obtiene una categoría MOS para cada uno de los flujos bidireccionales que conforman el lote aleatorio de datos de tráfico seleccionado (ver Figura 4.2.64).

```
(73, 17) Index(['ts', 'te', 'td', 'sa', 'da', 'sp', 'dp', 'pr', 'pkt', 'byt', 'fl',
              'bpp', 'pps', 'bps', 'tos', 'qt', 'nQoE_E'],
              dtype='object')
0      B
1      R
2      NET
3      R
4      R
...
73     R
74     R
75     R
76     R
78     R
Name: nQoE_E, Length: 73, dtype: object
```

Figura 4.2.64. NQoE\_E para un lote de datos de tráfico (Control - Marcación)

Finalmente, la comparación de categorías entre el NQoE\_P y NQoE\_E para el lote de 100 registros arroja un reporte de control de la QoE para cada uno de los usuarios dentro de la infraestructura del operador. La Figura 4.2.65 presenta los resultados para el lote seleccionado.

```
0      down1R
1      up1B
2      NET
3      down2MA
4      NC
...
73     NC
74     up1B
75     NC
76     down2MA
78     up1B
Name: report, Length: 73, dtype: object
```

	sa	da	report
0	185.53.91.24	163.117.142.115	down1R
1	104.196.50.168	163.117.142.218	up1B
2	185.208.209.6	163.117.142.108	NET
3	187.135.67.60	163.117.142.118	down2MA
4	163.117.142.214	163.117.131.61	NC
...	...	...	...
73	185.211.245.157	163.117.142.202	NC
74	185.254.122.17	163.117.142.220	up1B
75	163.117.142.208	216.58.201.163	NC
76	202.171.131.64	163.117.142.210	down2MA
78	52.155.172.105	163.117.142.213	up1B

a. Reporte QoE - lote

	sa	da	report
0	185.53.91.24	163.117.142.115	down1R
1	104.196.50.168	163.117.142.218	up1B
2	185.208.209.6	163.117.142.108	NET
3	187.135.67.60	163.117.142.118	down2MA
4	163.117.142.214	163.117.131.61	NC
5	194.7.77.126	163.117.142.206	NC
6	176.53.113.25	163.117.142.202	NC
7	124.133.15.51	163.117.142.209	up1E
8	185.176.27.174	163.117.142.217	up1B
9	89.42.103.183	163.117.142.106	up1B
10	192.168.20.2	163.117.142.108	down1ME

b. Reporte QOE – 10 registros

Figura 4.2.65. Reporte de control QoE (Control - comparación de niveles/reportes)

El reporte de la Figura 4.2.65 debe ser interpretado de la siguiente manera: para un usuario *da*, el modelo de predicción de la QoE reporta que ha mantenido, mejorado o disminuido la percepción de la calidad de servicios ofrecida por la Telco (i.e. NC, up, down, respectivamente). La mejora o disminución del nivel QoE es cuantificado por un número *n* de niveles asociados (e.g. up1); esto es, para el usuario 163.117.142.118 se esperaba un nivel de la QoE Bueno (B), pero el modelo ha detectado un nivel predicho de dos niveles por debajo (i.e. Malo -MA); mientras que para el usuario 163.117.142.217 se esperaba un nivel de QoE Regular (R), pero el modelo ha detectado un nivel predicho de un nivel por encima (i.e. Bueno). Finalmente, el reporte con categoría “NET” describe que el flujo es de categoría de servicio de control de red (e.g. flujos de control y gestión de la conexión SNMP.)

### 4.3. RECAPITULACIÓN

En este capítulo se presentó el desarrollo del macro-componente Operacional del Modelo QoE para servicios OTT. En particular, se detalla el modelo correlacional QoE-QoS a través de la operatividad de los perfiles conceptuales del modelo. La funcionalidad de cada perfil fue implementada en función de una necesidad particular del operador; esto es: monitorizar la QoE para el aprovisionamiento de servicios OTT dentro de su infraestructura de red (i.e. objetivo de negocio). Para ello, los perfiles de servicio, de usuario y paramétrico se correlacionan para el cumplimiento de una meta específica orientada a resolver la necesidad detectada en el operador. En efecto, la correlación de los perfiles del modelo tiene la finalidad de predecir un valor o nivel de QoE en el aprovisionamiento de servicios OTT a partir de un comportamiento de consumo del usuario y bajo unas condiciones de QoS presentes en el tráfico de red del operador, el cual pueda ser empleado en un sistema de monitorización de la QoE.

Si bien la definición conceptual de los perfiles del modelo permite diferentes implementaciones en función de otras necesidades particulares del operador (e.g. clasificación de tráfico por preferencias de consumo, oferta de paquetes de servicios por experiencia de usuario, segmentación de usuario por necesidad de consumo), la operatividad de estos dentro del modelo, responden a una meta específica donde el operador puede tener mayor control de la QoE de sus usuarios. En consecuencia, las fases de la metodología CRISP-DM fueron ajustadas a los requerimientos específicos de cada perfil; a saber:

- Perfil de servicio implementado por medio de las fases de comprensión del negocio y comprensión de los datos
- Perfil de usuario implementado a través de las fases de comprensión del negocio, comprensión de los datos, preparación de los datos, y modelado.
- Perfil paramétrico implementado dentro de las fases de preparación de los datos y modelado.

De igual manera, cada perfil resuelve desde su conceptualización y operatividad, los siguientes aspectos

- Perfil de servicio conceptualmente caracteriza los parámetros de QoS que mayor efecto tienen en la degradación de servicios OTT, y funcionalmente identifica aquellos parámetros QoS entregados por el operador para el tratamiento de los servicios.
- Perfil de usuario conceptualmente determina las características, condiciones, parámetros y medidas de QoE en la prestación de un servicio OTT, y funcionalmente relaciona el comportamiento y preferencias de consumo del usuario con la calidad de servicio percibida por este.
- Perfil paramétrico conceptualmente establece las condiciones y restricciones de prestación de un servicio OTT en la infraestructura de un operador de telecomunicaciones que mantenga una buena relación QoS-QoE, y funcionalmente estima o predice un nivel de QoE con base en los factores de influencia de QoS que afectan la prestación de un servicio OTT.

Por otro lado, se resaltan los siguientes aportes:

- Un conjunto de datos con una escala de valoración de la calidad de percepción del usuario luego del consumo de servicios OTT de su preferencia.
- Un conjunto de datos de tráfico de red con flujos bidireccionales de usuarios que consumen servicios OTT.
- Un conjunto de datos que relaciona los parámetros de flujo del tráfico de red con la percepción de la calidad del servicio
- Un mecanismo de transformación de la calidad percibida del usuario a una escala de valoración MOS para la determinación de la QoE
- Un modelo matemático de valoración de la percepción de la calidad del usuario luego del consumo de servicios OTT de su preferencia.
- Un modelo de etiquetado para un conjunto de datos de tráfico de red a partir de la valoración de la percepción de la calidad del servicio por parte de sus usuarios.
- Un modelo de gestión QoE para la fase de despliegue en el dominio de la Telco que emplea el modelo de predicción de la QoE.
- Un modelo de estimación de la QoE basada en la técnica CART para servicios OTT a partir de unas condiciones de QoS entregadas por el operador a sus usuarios.
- Una aproximación de un modelo de gestión QoE dentro de la infraestructura de red de la Telco

En síntesis, este capítulo presenta un esquema para la construcción de un modelo predictivo QoE, definido con el ánimo de estimar la percepción de la calidad de experiencia que tiene el usuario luego de consumir servicios OTT. El esquema considera datos centrados en el operador (i.e. tráfico) y datos centrados en el usuario (i.e. preferencia de consumo de servicio), lo cual permite tener una visión más general de la percepción de calidad de los usuarios; es decir, el esquema tiene en cuenta el contexto de la red y el contexto de usuario como componentes centrales del modelo predictivo.

## CAPÍTULO 5. CONCLUSIONES Y RECOMENDACIONES

En el presente trabajo de investigación se desarrolló un modelo de estimación de la QoE para servicios OTT a partir de la correlación entre las condiciones de QoS presentes en la red y algunos elementos de la QoE de los usuarios luego de consumir diferentes servicios. Para tal efecto, se estructuraron e implementaron dos macro-componentes de acuerdo con los lineamientos definidos por Y. Jabareen [61] para el desarrollo de marcos conceptuales y CRISP-DM [60] para el desarrollo de proyectos de minería de datos. El primer macro-componente, *Conceptualización*, presenta una rigurosa revisión del estado de la ciencia en el área de la QoE y define los elementos conceptuales del modelo QoE para servicios OTT. El segundo macro-componente, *Operacional*, presenta un modelo correlacional QoE-QoS que predice un valor o nivel de la QoE en el aprovisionamiento de servicios OTT a partir de un comportamiento de consumo del usuario y bajo unas condiciones de QoS presentes en el tráfico de red del operador.

Para el macro-componente de Conceptualización se tiene

- El mapa estratégico obtenido indica la evolución científica y tecnológica en el aprovisionamiento de la QoE para servicios OTT bajo condiciones de QoS, y sirve como base conceptual para la construcción de marcos de referencia para la gestión de la QoE.
- Los elementos conceptuales definidos en el modelo QoE representan los perfiles que caracterizan el aprovisionamiento de la QoE para servicios OTT; esto es: un perfil de servicio que describe las condiciones presentes de QoS en la red para el tratamiento de servicios OTT, un perfil de usuario que evalúa la experiencia de un usuario en términos del consumo de servicios OTT, y un perfil paramétrico que relaciona la información del comportamiento de la red con la calidad percibida por los usuarios luego de consumir servicios OTT.

Para el macro-componente Operacional se tiene

- Un esquema para la construcción de un modelo predictivo QoE, definido con el ánimo de estimar la percepción de la calidad de experiencia que tiene el usuario luego de consumir servicios OTT. El esquema considera datos centrados en el operador (i.e. tráfico) y datos centrados en el usuario (i.e. preferencia de consumo de servicio), lo cual permite tener una visión más general de la percepción de calidad de los usuarios; es decir, el esquema tiene en cuenta el contexto de la red y el contexto de usuario como componentes centrales del modelo predictivo.
- Las implementaciones de los elementos conceptuales del modelo de correlación QoS-QoE constituyen los bloques esenciales del modelo; esto es: un perfil de servicio, encargado de describir el comportamiento del tráfico de red, y el cual sirve como base en la construcción de mecanismos de clasificación y marcación de tráfico para servicios OTT. Un perfil de usuario, encargado de describir los elementos de contexto que afectan la QoE luego de consumir diferentes servicios, y el cual sirve como instrumento para el desarrollo de aplicativos de reconocimiento del contexto de consumo de servicios OTT por parte de los usuarios. Y un perfil paramétrico, encargado de relacionar la valoración de la QoE con las condiciones de tráfico presentes en cada uno de los flujos bidireccionales usuario-servicio, y el cual sirve como instrumento en la construcción de aplicaciones de monitorización y control de la QoE.
- El módulo de Recolección de los datos del modelo correlacional QoS-QoE determina los puntos clave en la obtención de los datos necesarios para la construcción del modelo predictivo. En particular, el contexto de red es representado por el protocolo Netflow, caracterizado por ser una estrategia de monitorización de

tráfico no invasiva y de aplicación real en el dominio de la Telco; y un contexto de usuario representado por la instrumentalización de un dispositivo de conexión del usuario que permite reunir información de consumo de servicios OTT (i.e. aplicación QoE\_MOS).

- El módulo de Preparación de datos del modelo de correlación QoS-QoE representa un punto crítico en la construcción del modelo predictivo, principalmente por su impacto en el desempeño de los algoritmos de aprendizaje automático. La limpieza y transformación de los datos es esencial para lograr los mejores resultados, por lo que esta fase demanda el mayor tiempo de realización dentro de un proyecto de aprendizaje automático. En particular, ciertas transformadas de datos afectan el desempeño de los algoritmos; esto es: escalamiento y transformación de la variable objetivo tienen un impacto significativo en las redes neuronales debido a su sensibilidad entre las escalas de las características de los datos.
- El módulo de Modelado del modelo de correlación QoS-QoE permite evaluar diferentes algoritmos de aprendizaje automático en la predicción de la QoE. En particular, los algoritmos Ridge y CART presentan los mejores resultados para los perfiles de usuario y paramétrico, respectivamente. Adicionalmente, el modelo semisupervisado propuesto para el perfil de usuario puede ser adaptado a un escenario de la Telco donde los datos de la percepción de la calidad sean inferiores en número a los datos monitorizados del consumo de servicios en el contexto del usuario.
- Los módulos definidos dentro del esquema de construcción de un modelo predictivo QoE, representan la operatividad de cada uno de los elementos conceptuales del modelo QoE para servicios OTT de acuerdo con una necesidad particular de la Telco (monitorizar la QoE para el aprovisionamiento de servicios OTT dentro de su infraestructura de red). A continuación se reseña cada uno, señalando a cuál de los objetivos específicos de la tesis de doctorado enumerados en la Sección 1.3.2 corresponde.:
  - El perfil de servicio, conceptualmente definido en el macro-componente Conceptualización para la caracterización de los parámetros de QoS que mayor efecto tienen en la degradación de servicios (objetivo específico 1), se implementó funcionalmente en el módulo de Recolección de datos del modelo correlacional QoS-QoE (del macro-componente Operacional) por medio de la identificación de aquellos parámetros QoS entregados por el operador para el tratamiento de los servicios.
  - El perfil de usuario, conceptualmente definido en el macro-componente Conceptualización para la determinación de las características, condiciones, parámetros y medidas de QoE en la prestación de un servicio OTT (objetivo específico 2), se implementó funcionalmente en los módulos de Recolección de datos, Preparación de datos, y Modelado del modelo correlacional QoS-QoE (del macro-componente Operacional) por medio de la correlación entre el comportamiento y preferencias de consumo del usuario con la calidad del servicio percibida por este.
  - El perfil paramétrico, conceptualmente definido en el macro-componente Conceptualización para el establecimiento de las condiciones y restricciones de prestación de un servicio OTT en la infraestructura de un operador de telecomunicaciones que mantenga una buena relación QoS-QoE (objetivo específico 3), se implementó funcionalmente en los módulos de Preparación de datos y Modelado del modelo correlacional QoS-QoE (del macro-componente Operacional) por medio de técnicas de aprendizaje automático adaptadas para la estimación de un nivel QoE con base en los factores de influencia de QoS que afectan la prestación de un servicio OTT (objetivo específico 4).
  - La evaluación del modelo de correlación (objetivo específico 5) se llevó a cabo a través de la evaluación de los perfiles. Los perfiles de usuario y paramétrico son evaluados de acuerdo con el diseño del esquema de comprobación propuesto para medir la calidad y validez de cada uno de los modelos; como resultado, un modelo basado en la técnica de aprendizaje automático Ridge presenta el mejor desempeño para estimar la percepción de la calidad del servicio a partir del comportamiento y preferencias de consumo del usuario, y un modelo basado en la técnica de aprendizaje automático

CART presenta el mejor desempeño para estimar un nivel de la QoE a partir de unas condiciones específicas de QoS entregadas por la Telco a sus usuarios.

- La evaluación del perfil del servicio está en términos de otra necesidad detectada en la Telco, donde prevalece conocer de manera no intrusiva el tipo de tráfico que transita sobre su infraestructura; como resultado, un modelo de clasificador de QoS [186] se presenta como una aproximación de caracterización y clasificación de tráfico dentro de la infraestructura de red del operador.

El conjunto de datos del perfil paramétrico permite relacionar la información de tráfico representada por descriptores de flujo y la QoE de los usuarios luego de consumir servicios OTT. Este conjunto de datos fusiona dos conjuntos de datos previamente elaborados y que pueden cumplir propósitos diferentes; esto es, un conjunto de datos estructurados de tráfico de red con flujos bidireccionales de usuarios que consumen servicios OTT, el cual puede ser usado para la definición de esquemas de clasificación de tráfico; y un conjunto de datos estructurado con escala de valoración de la calidad percibida por el usuario luego del consumo de servicios OTT de su preferencia, el cual puede ser usado para perfilar a los usuarios de acuerdo con los planes de datos ofrecidos por una Telco.

Los modelos matemáticos definidos para el perfil de servicio y el perfil paramétrico presentan una alternativa más estructurada para la valoración del QoE; esto es: un modelo matemático de valoración de la percepción de la calidad del servicio que pondera las preferencias del usuario de acuerdo con su comportamiento de consumo; y un modelo matemático de valoración de la percepción de la calidad del servicio con base en los flujos bidireccionales que representan el comportamiento el tráfico de la red.

Un mecanismo de transformación del valor de la percepción de la calidad del servicio en una escala de valoración subjetiva MOS permite a una Telco tener un panorama más descriptivo de la calidad de la experiencia de sus usuarios luego de consumir servicios OTT sobre su red de aprovisionamiento.

El modelo de correlación QoS-QoE puede ser empleado en sistemas gestión de la QoE donde se requiere por parte de la Telco un diagnóstico y monitorización más objetiva de la percepción de la calidad del servicio por parte de sus usuarios dentro su red de aprovisionamiento, y que le permite ajustar la configuración de la red para optimizar la relación satisfacción de usuarios vs. recursos asignados. Además, el modelo implementado permite ser explotado en escenarios comerciales donde el operador defina diferentes planes de acuerdo con la percepción de la calidad estimada.

El retardo, la variación del retardo y la pérdida de paquetes, son los parámetros establecidos para determinar el impacto de la QoS en cada una de las clases de servicios existentes. En [186] se presenta un clasificador de QoS desarrollado en el contexto de la presente tesis de doctorado, que toma como base estos parámetros y utiliza un modelo de aprendizaje basado en Bagging, obteniendo los mejores resultados para caracterizar y clasificar tráfico a partir del campo DSCP.

Los parámetros que afectan la QoE van más allá de aquellos caracterizados desde un punto de vista técnico del operador, abarcando parámetros del contexto de usuario que representan las condiciones donde la QoE puede variar. En particular, el comportamiento de consumo determina la percepción de la calidad del servicio por parte de los usuarios, donde las preferencias de estos varían en el tiempo.

Finalmente, como recomendaciones principales se destacan:

El perfil de usuario podría considerar más descriptores del contexto de usuario con el ánimo de ajustar la valoración de la percepción de la calidad del servicio. En efecto, la valoración del estado de ánimo puede ser una alternativa no intrusiva en el usuario para caracterizar otro parámetro de contexto. Para ello, la aplicación

QoE\_MOS puede ser adaptada para capturar el estado de ánimo del usuario a partir de una escala de valoración previamente definida.

El perfil del servicio podría considerar más descriptores de comportamiento de tráfico de acuerdo con los definidos por el protocolo Netflow y con aquellos desarrollados de manera propietaria con el ánimo de enriquecer el conjunto de datos que describen los flujos que transitan en la infraestructura de la Telco. En particular, descriptores como *srcvlan* y *dstvlan* permiten conocer las etiquetas fuentes y destino para rutas virtuales sobre la cual es proyectada la comunicación entre usuario-servicio (gestión de enlaces virtuales al interior de la infraestructura de la Telco); descriptores como *next* y *bgpNext* permiten conocer los saltos siguientes por los que transitará un determinado paquete (gestión de enrutamiento entre diferentes dominios de red del operador); y descriptores como *inif* y *outif* señalan las interfaces de entrada y salida del protocolo SNMP como elemento de gestión de la red. Lo anterior con el ánimo de tener mayor precisión de los recursos a asignar para un conjunto de servicios priorizados de acuerdo con la percepción de la calidad de los usuarios.

Los modelos obtenidos del entrenamiento de los algoritmos de aprendizaje pueden ser ajustados en sus hiperparámetros con el ánimo de obtener mejores resultados. En efecto, la sintonización de los hiperparámetros de los modelos permite evaluar diferentes combinaciones de los parámetros configurables en cada algoritmo con el ánimo de mejorar su desempeño [193], [225]; por ejemplo, el modelo basado en el algoritmo Ridge puede ser configurado con diferentes valores en su parámetro *alpha* (regularización), y el modelo basado en CART puede ser configurado con diferentes valores en sus parámetros de máxima profundidad, máximo número de características, y máxima cantidad de nodos por cada rama del árbol de decisión. Adicionalmente, modelos basados en conjuntos como Boosting y Bagging son una alternativa que puede ser empleada para el mejoramiento del desempeño del modelo de predicción, principalmente por ser técnicas que generan múltiples modelos a partir de los datos de entrenamiento, y los combinan para mejorar los resultados; por ejemplo, la implementación AdBoost para regresión [226], puede usar como base el algoritmo CART para la construcción de varios modelos que posteriormente serán combinados con el ánimo de mejorar los resultados en la estimación del nivel de la QoE.

Elementos característicos del usuario como sus necesidades y emociones pueden ser tenidas en cuenta para mejorar los sistemas de QoE en el aprovisionamiento de servicios OTT. En particular, aspectos tratados en el dominio de interacción humano-computadora dentro del campo de Experiencia de Usuario (UX) pueden ser adaptados para entender con mayor profundidad la subjetividad en la percepción de la calidad que tiene los usuarios luego de consumir diferentes servicios OTT.

## REFERENCIAS

- [1] Internet Live Stats, "Internet Live Stats," 2016. [Online]. Available: <http://www.internetlivestats.com/>. [Accessed: 07-Jun-2016].
- [2] Internet World Stats, "Internet Usage and Population Statistics," 2015. [Online]. Available: <http://www.internetworldstats.com/stats.htm>. [Accessed: 08-Jun-2016].
- [3] Cisco, "The Zettabyte Era : Trends and Analysis," 2016.
- [4] J. Sujata, S. Sohag, D. Tanu, D. Chintan, and P. Shubham, "Impact of Over the Top ( OTT ) Services on Telecom Service Providers," *Indian J. Sci. Technol.*, vol. 8, no. February, pp. 145–160, 2015.
- [5] MobileSquared, "From Resistance to Partnership Operators shift into monetising OTT Table of Contents," 2014.
- [6] J. Seppanen and M. Varela, "QoE-driven network management for real-time over-the-top multimedia services," in *IEEE Wireless Communications and Networking Conference, WCNC*, 2013, pp. 1621–1626.
- [7] E. Ibarrola, F. Liberal, and A. Ferro, "Introduction to Quality of Service," in *Intelligent Quality of Service Technologies and Network Management*, vol. 1, K. Klinger, J. Mosemann, L. Johnston, C. Bufton, S. Woznicki, M. Harty, J. Snavely, and L. Tosheff, Eds. IGI Global., 2010, pp. 26–14.
- [8] ITU-T E.800, "Definition of terms related to quality of service," 2008.
- [9] M. Fiedler, S. Möller, and P. Reichl, "Quality of Experience: From User Perception to Instrumental Metrics (Dagstuhl Seminar 12181)," Schloss Dagstuhl–Leibniz-Zentrum fuer Informatik, Dagstuhl, Germany, 2012.
- [10] P. Le Callet, S. Möller, and A. Perkis, Eds., "Qualinet white paper on definitions of quality of experience (2012) - Output version of the Dagstuhl seminar 12181," in *European Network on Quality of Experience in Multimedia Systems and Services (COST IC 1003)*, 2012.
- [11] K. De Moor, M. Fiedler, P. Reichl, and M. Varela, "Quality of Experience: From Assessment to Application (Dagstuhl Seminar 15022)," 2015.
- [12] U. Reiter *et al.*, "Factors Influencing Quality of Experience .," in *Quality of Experience Advanced Concepts, Applications and Methods*, S. Möller, A. Küpper, and A. Raake, Eds. Springer, 2014, pp. 55–72.
- [13] Statista, "Netflix logra una cifra récord de suscriptores internacionales | Statista," 2020. [Online]. Available: <https://es.statista.com/grafico/17753/netflix-sigue-creciendo-internacionalmente/>. [Accessed: 10-Apr-2020].
- [14] K. Petersen, R. Feldt, S. Mujtaba, and M. Mattsson, "Systematic mapping studies in software engineering," in *EASE'08 Proceedings of the 12th international conference on Evaluation and Assessment in Software Engineering*, 2008, pp. 68–77.
- [15] C. Aurrecochea, A. T. Campbell, and L. Hauw, "A survey of QoS architectures," *Multimed. Syst.*, vol. 6, no. 3, pp. 138–151, May 1998.
- [16] J. Evans and C. Filsfils, "QoS Requirements and Service Level Agreements," in *Deploying IP and MPLS QoS for Multiservice Networks*, Elsevier, 2007, pp. 1–86.
- [17] H. Rahman, N. Ahmed, and M. I. Hussain, "A hybrid data aggregation scheme for provisioning Quality of Service (QoS) in Internet of Things (IoT)," in *2016 Cloudification of the Internet of Things (CloT)*, 2016, pp. 1–5.
- [18] N. S. Bhirud and S. B. Tatala, "Optimization of quality of service (QoS) parameters using Contract Net Protocol in Ubiquitous Computing," in *2016 International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT)*, 2016, pp. 1126–1130.
- [19] M. Faheem, G. Tuna, and V. C. Gungor, "QERP: Quality-of-Service (QoS) Aware Evolutionary Routing Protocol for Underwater Wireless Sensor Networks," *IEEE Syst. J.*, vol. 12, no. 3, pp. 2066–2073, Sep. 2018.
- [20] P. Habibi, M. Mokhtari, and M. Sabaei, "QRVE: QoS-aware routing and energy-efficient VM Placement for Software-Defined DataCenter Networks," in *2016 8th International Symposium on Telecommunications (IST)*, 2016, pp. 533–539.

- [21] M. Varela, L. Skorin-Kapov, F. Guyard, and M. Fiedler, "Meta-Modeling QoE," *PIK - Prax. der Informationsverarbeitung und Kommun.*, vol. 37, no. 4, 2014.
- [22] P. Reichl et al., "Towards a comprehensive framework for QOE and user behavior modelling," in *2015 Seventh International Workshop on Quality of Multimedia Experience (QoMEX)*, 2015, pp. 1–6.
- [23] M. D. Stojanovic, M. M. Vukasinovic, and V. M. R. Djogatovic, "Approaches to Quality of Experience Management in the Future Internet," in *Telecommunication in Modern Satellite, Cable and Broadcasting Services (TELSIKS), 2015 12th International Conference on*, 2015, pp. 281–288.
- [24] S. Battilotti, F. Delli Priscoli, C. Gori Giorgi, and A. Pietrabissa, "Approaches for Future Internet architecture design and Quality of Experience ( QoE ) Control," *WSEAS Trans. Commun.*, vol. 14, pp. 62–73, 2015.
- [25] S. Yuan, T. Lin, S. Bai, and S. Ci, "User-oriented QoE-driven server selection for multimedia service provisioning in content distribution networks," *IEEE Int. Symp. Pers. Indoor Mob. Radio Commun. PIMRC*, vol. 2015-Decem, pp. 2077–2082, 2015.
- [26] B. Lewcio and S. Möller, "A testbed for QoE-based multimedia streaming optimization in heterogeneous wireless networks," *5th Int. Conf. Signal Process. Commun. Syst. ICSPCS'2011 - Proc.*, 2011.
- [27] S. Singh, O. Oyman, A. Papathanassiou, D. Chatterjee, and J. G. Andrews, "Video capacity and QoE enhancements over LTE," *IEEE Int. Conf. Commun.*, pp. 7071–7076, 2012.
- [28] K. Mitra, C. Ahlund, and A. Zaslavsky, "QoE estimation and prediction using hidden Markov models in heterogeneous access networks," *Australas. Telecommun. Networks Appl. Conf. 2012*, pp. 1–5, 2012.
- [29] E. Liotou, D. Tsolkas, and N. Passas, "A roadmap on QoE metrics and models," *2016 23rd Int. Conf. Telecommun. ICT 2016*, 2016.
- [30] K. De Vogeleer, S. Ickin, M. Fiedler, D. Erman, and A. Popescu, "Estimation of Quality of Experience in 3G Networks with the Mahalanobis Distance," in *The Fourth International Conference on Communication Theory, Reliability, and Quality of Service Estimation - CTRQ 2011*, 2011, pp. 72–77.
- [31] Body of European Regulators of Electronic Communications (BEREC), "Report on OTT services," 2016.
- [32] A. Nandhiasa and S. Haryadi, "Indonesian regulation management recommendation for Over-the-Top services," in *2015 1st International Conference on Wireless and Telematics (ICWT)*, 2015, pp. 1–4.
- [33] C. Barclay, "Is regulation the answer to the rise of over the top (OTT) services? An exploratory study of the Caribbean market," in *2015 ITU Kaleidoscope: Trust in the Information Society (K-2015)*, 2015, vol. 3, pp. 1–8.
- [34] D. Rivera Villagra and A. R. Cavalli, "Analysis and Influence of Economical Decisions on the Quality of Experience of OTT Services," *IEEE Lat. Am. Trans.*, vol. 14, no. 6, pp. 2773–2776, 2016.
- [35] S. A. Jensen, M. Jensen, and J. M. Gutierrez, "Caching over-the-top services, the Netflix case," *2015 Int. Conf. Comput. Netw. Commun. ICNC 2015*, pp. 1081–1086, 2015.
- [36] I. D. Lutilsky and M. Ivic, "Influence of OTT service providers on Croatian telecommunication market," *2016 39th Int. Conv. Inf. Commun. Technol. Electron. Microelectron. MIPRO 2016 - Proc.*, pp. 711–715, 2016.
- [37] W. Dai, J. W. Baek, and S. Jordan, "Modeling the impact of QoS pricing on ISP integrated services and OTT services," *Proc. 11th Int. Conf. Netw. Serv. Manag. CNSM 2015*, pp. 85–91, 2015.
- [38] D. Saucez, S. Secci, and C. Barakat, "On the incentives and incremental deployments of ICN technologies for OTT services," *IEEE Netw.*, vol. 28, no. 3, pp. 20–25, 2014.
- [39] F. H. Huang, W. A. Zhou, and Y. Du, "QoE issues of OTT services over 5G network," *Proc. - 2014 9th Int. Conf. Broadband Wirel. Comput. Commun. Appl. BWCCA 2014*, pp. 267–273, 2014.
- [40] P. A. Frangoudis, Y. Hadjadj-Aoul, A. Ksentini, G. Rubino, T. Etame, and C. Brun, "PTPv2-based network load estimation and its application to QoE monitoring for Over-the-Top services," *IISA 2014 - 5th Int. Conf. Information, Intell. Syst. Appl.*, pp. 176–181, 2014.
- [41] M. Alreshoodi and J. Woods, "Survey on QoE\QoS Correlation Models for Multimedia Services," *Int. J. Distrib. Parallel Syst.*, vol. 4, no. 3, pp. 53–72, 2013.
- [42] S. Aroussi and A. Mellouk, "Survey on machine learning-based QoE-QoS correlation models," in *International Conference on Computing, Management and Telecommunications, ComManTel 2014*,

- 2014, pp. 200–204.
- [43] M. S. Mushtaq, B. Augustin, and A. Mellouk, “Empirical study based on machine learning approach to assess the QoS/QoE correlation,” in *2012 17th European Conference on Networks and Optical Communications*, 2012, pp. 1–7.
- [44] S. Aroussi, T. Bouabana-Tebibel, and A. Mellouk, “Empirical QoE/QoS correlation model based on multiple parameters for VoD flows,” *GLOBECOM - IEEE Glob. Telecommun. Conf.*, vol. 2, no. 1, pp. 1963–1968, 2012.
- [45] Y. Zhang, T. Yue, H. Wang, and A. Wei, “Predicting the Quality of Experience for Internet Video with Fuzzy Decision Tree,” in *2014 IEEE 17th International Conference on Computational Science and Engineering*, 2014, pp. 1181–1187.
- [46] S. Jana, A. Chan, A. Pande, and P. Mohapatra, “QoE prediction model for mobile video telephony,” *Multimed. Tools Appl.*, vol. 75, no. 13, pp. 7957–7980, Jul. 2016.
- [47] Dandelion API, “Open Big Data,” 2014. [Online]. Available: <https://dandelion.eu/datamine/open-big-data/>. [Accessed: 18-Apr-2021].
- [48] V. Menkovski, G. Exarchakos, and A. Liotta, “Online QoE prediction,” in *2010 2nd International Workshop on Quality of Multimedia Experience, QoMEX 2010 - Proceedings*, 2010, pp. 118–123.
- [49] N. Bouten *et al.*, “A multicast-enabled delivery framework for QoE assurance of over-the-top services in multimedia access networks,” *J. Netw. Syst. Manag.*, vol. 21, no. 4, pp. 677–706, 2013.
- [50] R. Schatz, M. Fiedler, and L. Skorin-Kapov, “QoE-Based Network and Application Management,” in *Quality of Experience Advanced Concepts, Applications and Methods*, S. Moller, A. Küpper, and A. Raake, Eds. 2014, pp. 411–426.
- [51] M. Finsterbusch, C. Richter, E. Rocha, J. A. Müller, and K. Hänßgen, “A survey of payload-based traffic classification approaches,” *IEEE Commun. Surv. Tutorials*, vol. 16, no. 2, pp. 1135–1156, 2014.
- [52] L. Martins, J. Lopes, J. Craveirinha, J. Climaco, R. Cadime, and C. Monica, “Network performance improvement through evaluation of bicriteria routing methods in transport networks,” in *9th International Conference on Network and Service Management (CNSM 2013)*, 2013, pp. 34–41.
- [53] H. Wang, L. Song, H. Chen, and L. Yan, “Study on network measurement technologies and performance evaluation methods,” in *Cross Strait Quad-Regional Radio Science and Wireless Technology Conference, CSQRWC 2013*, 2013, no. 61072043, pp. 377–380.
- [54] H. Zhang, “Network Performance Reliability Evaluation Based on Network Reduction,” in *Reliability and Maintainability Symposium*, 2014, pp. 1–6.
- [55] A. Dainotti, A. Pescapè, and K. C. Claffy, “Issues and future directions in traffic classification,” *IEEE Netw.*, vol. 26, no. 1, pp. 35–40, 2012.
- [56] N. Al Khater and R. E. Overill, “Network Traffic Classification Techniques and Challenges,” in *The Tenth International Conference on Digital Information Management (ICDIM 2015)*, 2015, pp. 43–48.
- [57] S. E. Middleton and S. Modafferi, “Scalable classification of QoS for real-time interactive applications from IP traffic measurements,” *Comput. Networks*, vol. 107, no. Part 1, pp. 121–132, Oct. 2016.
- [58] C. Serrano, “Modelo Integral para el Profesional en Ingeniería.” Universidad del Cauca, 2008.
- [59] B. Kitchenham and S. Charters, “Guidelines for performing Systematic Literature reviews in Software Engineering Version 2.3,” Durham, 2007.
- [60] IBM, “Manual CRISP-DM de IBM SPSS Modeler,” 2012.
- [61] Y. Jabareen, “Building a Conceptual Framework: Philosophy, Definitions, and Procedure,” *Int. J. Qual. Methods*, vol. 8, no. 4, pp. 49–62, Dec. 2009.
- [62] M. Gusenbauer and N. R. Haddaway, “Which academic search systems are suitable for systematic reviews or meta-analyses? Evaluating retrieval qualities of Google Scholar, PubMed, and 26 other resources,” *Res. Synth. Methods*, vol. 11, no. 2, pp. 181–217, 2020.
- [63] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, “SciMAT: A new science mapping analysis software tool,” *J. Am. Soc. Inf. Sci. Technol.*, vol. 63, no. 8, pp. 1609–1630, Aug. 2012.
- [64] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, “An approach for detecting, quantifying, and visualizing the evolution of a research field: A practical application to the Fuzzy Sets

- Theory field,” *J. Informetr.*, vol. 5, no. 1, pp. 146–166, 2011.
- [65] Soft Computing and Intelligent Information Systems Group, “SciMAT - Science Mapping Analysis Tool,” 2016. [Online]. Available: <https://sci2s.ugr.es/scimat/>. [Accessed: 11-Apr-2020].
- [66] M. Callon, J. P. Courtial, and F. Laville, “Co-word analysis as a tool for describing the network of interactions between basic and technological research: The case of polymer chemistry,” *Scientometrics*, vol. 22, no. 1, pp. 155–205, Sep. 1991.
- [67] Qualinet, “QUALINET - COST IC 1003.” [Online]. Available: <http://www.qualinet.eu/>. [Accessed: 11-Apr-2020].
- [68] Schloss Dagstuhl, “Schloss Dagstuhl: Seminar Homepage.” [Online]. Available: [https://www.dagstuhl.de/no\\_cache/en/program/calendar/semhp/?semnr=16472](https://www.dagstuhl.de/no_cache/en/program/calendar/semhp/?semnr=16472). [Accessed: 11-Apr-2020].
- [69] S. Chandra, C. S. Ellis, and A. Vahdat, “Application-level differentiated multimedia web services using quality aware transcoding,” *IEEE J. Sel. Areas Commun.*, vol. 18, no. 12, pp. 2544–2565, 2000.
- [70] A. Ziviani, J. F. De Rezende, and O. C. M. B. Duarte, “Evaluating the expedited forwarding of voice traffic in a differentiated services network,” *Int. J. Commun. Syst.*, vol. 15, no. 9, pp. 799–813, 2002.
- [71] G. Ghinea and M. C. Angelides, “A User Perspective of Quality of Service in m-Commerce,” *Multimed. Tools Appl.*, vol. 22, no. 2, pp. 187–206, 2004.
- [72] A. K. Talukdar, B. R. Badrinath, and A. Acharya, “MRSVP: A resource reservation protocol for an integrated services network with mobile hosts,” *Wirel. Networks*, vol. 7, no. 1, pp. 5–19, 2001.
- [73] Q. Zhang, V. M. Vokkarane, J. P. Jue, and B. Chen, “Absolute QoS differentiation in optical burst-switched networks,” *IEEE J. Sel. Areas Commun.*, vol. 22, no. 9, pp. 1781–1795, 2004.
- [74] M. Mirhakkak, N. Schult, and D. Thomson, “Dynamic bandwidth management and adaptive applications for a variable bandwidth wireless environment,” *IEEE J. Sel. Areas Commun.*, vol. 19, no. 10, pp. 1984–1997, 2001.
- [75] M. A. Siller and J. Woods, “QoE in multimedia services transmission,” in *7TH WORLD MULTICONFERENCE ON SYSTEMICS, CYBERNETICS AND INFORMATICS, VOL VII, PROCEEDINGS*, 2003, pp. 74–76.
- [76] M. Mbise and J. Woods, “Development of quality of experience metric using application and network level QoS considerations,” in *7TH WORLD MULTICONFERENCE ON SYSTEMICS, CYBERNETICS AND INFORMATICS, VOL, III, PROCEEDINGS: COMMUNICATION, NETWORK AND CONTROL SYSTEMS, TECHNOLOGIES AND APPLICATIONS*, 2003, pp. 9–12.
- [77] H. De Meer, A. La Corte, A. Puliafito, and O. Tomarchio, “Programmable agents for flexible QoS management in IP networks,” *IEEE J. Sel. Areas Commun.*, vol. 18, no. 2, pp. 256–267, 2000.
- [78] E. W. Fulp and D. S. Reeves, “Bandwidth provisioning and pricing for networks with multiple classes of service,” *Comput. Networks*, vol. 46, no. 1, pp. 41–52, 2004.
- [79] N. Muruganatha and H. Lutfiyya, “Policy specification and architecture for Quality of Service management,” *IFIP Adv. Inf. Commun. Technol.*, vol. 118, pp. 535–548, 2003.
- [80] S. D. Patek, R. Venkateswaran, and J. Liebeherr, “Simple alternate routing for differentiated services networks,” *Comput. Networks*, vol. 37, no. 3–4, pp. 447–466, 2001.
- [81] J. A. Van Mieghem, “Price and service discrimination in queueing systems: incentive compatibility of Gc<sub>u</sub> scheduling,” *Manage. Sci.*, vol. 46, no. 9, pp. 1249–1267, 2000.
- [82] M. Moh and B. Nguyen, “QoS-guaranteed one-to-many and many-to-many multicast routing,” *Comput. Commun.*, vol. 26, no. 7, pp. 652–669, 2003.
- [83] E. Gelenbe, R. Lent, and Z. Xu, “Design and performance of cognitive packet networks,” *Perform. Eval.*, vol. 46, no. 2–3, pp. 155–176, 2001.
- [84] G. R. Ash, “Performance evaluation of QoS-routing methods for IP-based multiservice networks,” *Comput. Commun.*, vol. 26, no. 8, pp. 817–833, 2003.
- [85] J. Shaikh, M. Fiedler, and D. Collange, “Quality of Experience from user and network perspectives,” *Ann. Telecommun.*, vol. 65, no. 1–2, pp. 47–57, Feb. 2010.
- [86] K. De Moor *et al.*, “Proposed framework for evaluating quality of experience in a mobile, testbed-oriented

- living lab setting,” *Mob. Networks Appl.*, vol. 15, no. 3, pp. 378–391, 2010.
- [87] R. Serral-Gracià, E. Cerqueira, M. Curado, M. Yannuzzi, E. Monteiro, and X. Masip-Bruin, “An overview of quality of experience measurement challenges for video applications in IP networks,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 6074 LNCS, pp. 252–263, 2010.
- [88] H. J. K. H. J. Kim and S. G. C. S. G. Choi, “A study on a QoS/QoE correlation model for QoE evaluation on IPTV service,” *Adv. Commun. Technol. (ICACT), 2010 12th Int. Conf.*, vol. 2, pp. 1377–1382, 2010.
- [89] T. Y. Huang, K. T. Chen, and P. Huang, “Tuning Skype’s redundancy control algorithm for user satisfaction,” *Proc. - IEEE INFOCOM*, pp. 1179–1187, 2009.
- [90] M. Graubner, P. S. Mogre, R. Steinmetz, and T. Lorenzen, “A New QoE Model and Evaluation Method for Broadcast Audio Contribution over IP,” in *Proceedings of the 20th International Workshop on Network and Operating Systems Support for Digital Audio and Video*, 2010, pp. 57–62.
- [91] Y. Li, Z. Li, M. Chiang, and A. Robert Calderbank, “Content-aware distortion-fair video streaming in congested networks,” *IEEE Trans. Multimed.*, vol. 11, no. 6, pp. 1182–1193, 2009.
- [92] P. Ameigeiras, J. J. Ramos-Munoz, J. Navarro-Ortiz, P. Mogensen, and J. M. Lopez-Soler, “QoE oriented cross-layer design of a resource allocation algorithm in beyond 3G systems,” *Comput. Commun.*, vol. 33, no. 5, pp. 571–582, 2010.
- [93] L. Lu, W. A. Zhou, and S. Junde, “Quantitative customer perception evaluation for telecommunication service,” *2008 3rd Int. Conf. Pervasive Comput. Appl. ICPCA08*, vol. 2, pp. 912–915, 2008.
- [94] Y. Du, W. A. Zhou, B. Chen, and J. De Song, “A QoE based Evaluation of service quality in wireless communication network,” *Proc. - 2009 Int. Conf. New Trends Inf. Serv. Sci. NISS 2009*, pp. 552–557, 2009.
- [95] R. C. Elliott and W. A. Krzymień, “Downlink scheduling via genetic algorithms for multiuser single-carrier and multicarrier MIMO systems with dirty paper coding,” *IEEE Trans. Veh. Technol.*, vol. 58, no. 7, pp. 3247–3262, 2009.
- [96] M. M. Rashid, M. J. Hossain, E. Hossain, and V. K. Bhargava, “Opportunistic spectrum scheduling for multiuser cognitive radio: A queueing analysis,” *IEEE Trans. Wirel. Commun.*, vol. 8, no. 10, pp. 5259–5269, 2009.
- [97] C. Luo, F. R. Yu, H. Ji, and V. C. M. Leung, “Cross-layer design for TCP performance improvement in cognitive radio networks,” *IEEE Trans. Veh. Technol.*, vol. 59, no. 5, pp. 2485–2495, 2010.
- [98] R. Prodan and V. Nae, “Prediction-based real-time resource provisioning for massively multiplayer online games,” *Futur. Gener. Comput. Syst.*, vol. 25, no. 7, pp. 785–793, 2009.
- [99] M. M. Rashid, M. J. Hossain, E. Hossain, and V. K. Bhargava, “Opportunistic spectrum access in cognitive radio networks: A queueing analytic model and admission controller design,” *GLOBECOM - IEEE Glob. Telecommun. Conf.*, pp. 4647–4652, 2007.
- [100] E. Gelenbe, P. Liu, and J. Lainé, “Genetic algorithms for route discovery,” *IEEE Trans. Syst. Man, Cybern. Part B Cybern.*, vol. 36, no. 6, pp. 1247–1254, 2006.
- [101] N. Baldo and M. Zorzi, “Cognitive network access using fuzzy decision making,” *IEEE Trans. Wirel. Commun.*, vol. 8, no. 7, pp. 3523–3535, Jul. 2009.
- [102] H. J. Park, J. H. Yang, J. K. Choi, and H. S. Kim, “QoS negotiation for IPTV service using SIP,” *Int. Conf. Adv. Commun. Technol. ICACT*, vol. 2, pp. 945–948, 2007.
- [103] I. Gutiérrez, F. Bader, J. Pijoan, and S. Ben Slimane, “Adaptive resource management for a MC-CDMA system with mixed QoS classes using a cross layer strategy,” *IEEE Veh. Technol. Conf.*, pp. 3036–3040, 2007.
- [104] Q. He, J. Yan, H. Jin, and Y. Yang, “Service trust: Supporting reputation-oriented service selection,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 5900 LNCS, pp. 269–284, 2009.
- [105] S. Tursunova, K. Inoyatov, and Y. T. Kim, “Cognitive estimation of the available bandwidth in home/office network considering hidden/exposed terminals,” *IEEE Trans. Consum. Electron.*, vol. 56, no. 1, pp. 97–105, 2010.

- [106] X. Chen, Z. Zheng, and M. R. Lyu, "QoS-Aware Web Service Recommendation via Collaborative Filtering," in *Web Services Foundations*, New York, NY: Springer New York, 2014, pp. 563–588.
- [107] Z. Zheng, H. Ma, M. R. Lyu, and I. King, "Collaborative web service qos prediction via neighborhood integrated matrix factorization," *IEEE Trans. Serv. Comput.*, vol. 6, no. 3, pp. 289–299, 2013.
- [108] Z. Zheng, X. Wu, Y. Zhang, M. R. Lyu, and J. Wang, "QoS Ranking Prediction for Cloud Services," *IEEE Trans. Parallel Distrib. Syst.*, vol. 24, no. 6, pp. 1213–1222, Jun. 2013.
- [109] R. Stankiewicz and A. Jajszczyk, "A survey of QoE assurance in converged networks," *Comput. Networks*, vol. 55, no. 7, pp. 1459–1473, 2011.
- [110] S. Jelassi, G. Rubino, H. Melvin, H. Youssef, and G. Pujolle, "Quality of experience of VoIP service: A survey of assessment approaches and open issues," *IEEE Commun. Surv. Tutorials*, vol. 14, no. 2, pp. 491–513, 2012.
- [111] A. Ahmed, L. M. Boulahia, and D. Gaïti, "Enabling vertical handover decisions in heterogeneous wireless networks: A state-of-the-art and a classification," *IEEE Commun. Surv. Tutorials*, vol. 16, no. 2, pp. 776–811, 2014.
- [112] A. El Essaili, D. Schroeder, E. Steinbach, D. Staehle, and M. Shehada, "QoE-based traffic and resource management for adaptive HTTP video delivery in LTE," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 25, no. 6, pp. 988–1001, 2015.
- [113] A. N. Zaki and A. O. Fapojuwo, "Optimal and efficient graph-based resource allocation algorithms for multiservice frame-based OFDMA networks," *IEEE Trans. Mob. Comput.*, vol. 10, no. 8, pp. 1175–1186, 2011.
- [114] C. Sacchi, F. Granelli, and C. Schlegel, "A QoE-oriented strategy for OFDMA radio resource allocation based on min-MOS maximization," *IEEE Commun. Lett.*, vol. 15, no. 5, pp. 494–496, 2011.
- [115] J. Hu, G. Min, W. Jia, and M. E. Woodward, "Comprehensive QoS analysis of enhanced distributed channel access in wireless local area networks," *Inf. Sci. (Ny)*, vol. 214, pp. 20–34, 2012.
- [116] W. Cherif, A. Ksentini, D. Negru, and M. Sidibe, "A\_PSQA: Efficient real-time video streaming QoE tool in a future media internet context," in *2011 IEEE International Conference on Multimedia and Expo*, 2011, pp. 1–6.
- [117] Y. Chen, K. Wu, and Q. Zhang, "From QoS to QoE: A tutorial on video quality assessment," *IEEE Commun. Surv. Tutorials*, vol. 17, no. 2, pp. 1126–1165, 2015.
- [118] V. K. Adhikari *et al.*, "Measurement Study of Netflix, Hulu, and a Tale of Three CDNs," *IEEE/ACM Trans. Netw.*, vol. 23, no. 6, pp. 1984–1997, 2015.
- [119] M. S. Mushtaq, S. Fowler, A. Mellouk, and B. Augustin, "QoE/QoS-aware LTE downlink scheduler for VoIP with power saving," *J. Netw. Comput. Appl.*, vol. 51, pp. 29–46, 2015.
- [120] M. S. Mushtaq, B. Augustin, and A. Mellouk, "QoE-based LTE downlink scheduler for VoIP," *IEEE Wirel. Commun. Netw. Conf. WCNC*, vol. 3, pp. 2190–2195, 2014.
- [121] A. Alfayly, I. H. Mkwawa, L. Sun, and E. Ifeachor, "QoE-driven LTE downlink scheduling for VoIP application," *2015 12th Annu. IEEE Consum. Commun. Netw. Conf. CCNC 2015*, pp. 603–604, 2015.
- [122] S. K. Singh, T. Das, and A. Jukan, "A Survey on Internet Multipath Routing and Provisioning," *IEEE Commun. Surv. Tutorials*, vol. 17, no. 4, pp. 2157–2175, 2015.
- [123] S. Lirio Castellanos-Lopez, F. A. Cruz-Perez, M. E. Rivero-Angeles, and G. Hernandez-Valdez, "Erlang capacity in coordinated cognitive radio networks with stringent-delay applications," in *2013 IEEE 24th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, 2013, pp. 3166–3170.
- [124] D. Bruneo, "A stochastic model to investigate data center performance and qos in IaaS cloud computing systems," *IEEE Trans. Parallel Distrib. Syst.*, vol. 25, no. 3, pp. 560–569, 2014.
- [125] M. Klymash, M. Beshley, B. Strykhalyuk, and T. Maksymyuk, "Research and development the methods of quality of service provision in Mobile Cloud systems," *2014 IEEE Int. Black Sea Conf. Commun. Networking, BlackSeaCom 2014*, pp. 160–164, 2014.
- [126] T. Zahir, K. Arshad, A. Nakata, and K. Moessner, "Interference management in femtocells," *IEEE Commun. Surv. Tutorials*, vol. 15, no. 1, pp. 293–311, 2013.

- [127] F. Ongaro, E. Cerqueira, L. Foschini, A. Corradi, and M. Gerla, "Enhancing the quality level support for real-time multimedia applications in software-defined networks," *2015 Int. Conf. Comput. Netw. Commun. ICNC 2015*, pp. 505–509, 2015.
- [128] N. F. Huang, I. J. Liao, H. W. Liu, S. J. Wu, and C. S. Chou, "A dynamic QoS management system with flow classification platform for software-defined networks," *2015 8th Int. Conf. Ubi-Media Comput. UMEDIA 2015 - Conf. Proceedings*, pp. 72–77, 2015.
- [129] K. Mitra, A. Zaslavsky, and C. Ahlund, "Context-Aware QoE Modelling, Measurement, and Prediction in Mobile Computing Systems," *IEEE Trans. Mob. Comput.*, vol. 14, no. 5, pp. 920–936, 2015.
- [130] M. A. Santos, J. Villalón, and L. Orozco-Barbosa, "A novel QoE-aware multicast mechanism for video communications over IEEE 802.11 WLANs," *IEEE J. Sel. Areas Commun.*, vol. 30, no. 7, pp. 1205–1214, 2012.
- [131] S. Ickin, M. Fiedler, K. Wac, P. Arlos, C. Temiz, and K. Mkocho, "VLQoE: Video QoE instrumentation on the smartphone," *Multimed. Tools Appl.*, vol. 74, no. 2, pp. 381–411, 2014.
- [132] T. De Pessemier, K. De Moor, I. Ketykó, W. Joseph, L. De Marez, and L. Martens, "Investigating the influence of QoS on personal evaluation behaviour in a mobile context," *Multimed. Tools Appl.*, vol. 57, no. 2, pp. 335–358, 2012.
- [133] A. Najjar, C. Gravier, X. Serpaggi, and O. Boissier, "Multi-agent Systems for Personalized QoE-Management," *Proc. 28th Int. Teletraffic Congr. ITC 2016*, vol. 3, pp. 1–6, 2017.
- [134] E. Grigoriou, A. A. Barakabitze, L. Atzori, L. Sun, and V. Pilloni, "An SDN-approach for QoE management of multimedia services using resource allocation," *IEEE Int. Conf. Commun.*, 2017.
- [135] T. Zhao, Q. Liu, and C. W. Chen, "QoE in Video Transmission: A User Experience-Driven Strategy," *IEEE Commun. Surv. Tutorials*, vol. 19, no. 1, pp. 285–302, 2017.
- [136] A. Bentaleb, B. Taani, A. C. Begen, C. Timmerer, and R. Zimmermann, "A survey on bitrate adaptation schemes for streaming media over HTTP," *IEEE Commun. Surv. Tutorials*, vol. 21, no. 1, pp. 562–585, 2019.
- [137] V. Chervenets, V. Romanchuk, H. Beshley, and A. Khudyy, "QoS/QoE correlation modified model for QoE evaluation on video service," *Mod. Probl. Radio Eng. Telecommun. Comput. Sci. Proc. 13th Int. Conf. TCSET 2016*, vol. 6, pp. 664–666, 2016.
- [138] B. Ćurguz, D. Ilišević, and A. F. Kpis, "Mapping of QoS / QoE in 5G Networks," *2019 42nd Int. Conv. Inf. Commun. Technol. Electron. Microelectron.*, pp. 404–408, 2019.
- [139] M. Usman, N. Yang, M. A. Jan, X. He, M. Xu, and K. M. Lam, "A Joint Framework for QoS and QoE for Video Transmission over Wireless Multimedia Sensor Networks," *IEEE Trans. Mob. Comput.*, vol. 17, no. 4, pp. 746–759, 2018.
- [140] S. Khairi, M. Bellafkih, and B. Raouyane, "QoS management SDN-based for LTE/EPC with QoE evaluation: IMS use case," *2017 4th Int. Conf. Softw. Defin. Syst. SDS 2017*, pp. 125–130, 2017.
- [141] Z. Ning, Y. Liu, X. Wang, Y. Feng, and X. Kong, "A novel QoS-based QoE evaluation method for streaming video service," *Proc. - 2017 IEEE Int. Conf. Internet Things, IEEE Green Comput. Commun. IEEE Cyber, Phys. Soc. Comput. IEEE Smart Data, iThings-GreenCom-CPSCoM-SmartData 2017*, vol. 2018-Janua, pp. 956–961, 2018.
- [142] M. Agiwal, A. Roy, and N. Saxena, "Next generation 5G wireless networks: A comprehensive survey," *IEEE Commun. Surv. Tutorials*, vol. 18, no. 3, pp. 1617–1655, 2016.
- [143] S. Li, Z. Guo, G. Shou, Y. Hu, and H. Li, "QoE analysis of NFV-based mobile edge computing video application," *Proc. 2016 5th Int. Conf. Netw. Infrastruct. Digit. Content, IEEE IC-NIDC 2016*, pp. 411–415, 2017.
- [144] D.-H. Shin, "A User-based Model for the Quality of Experience of the Internet of Things," *Inf. Manag.*, vol. 54, no. 8, pp. 998–1011, Dec. 2017.
- [145] C. Gueguen and M. Manini, "Fairness-Energy-Throughput Optimized Trade-off in Wireless Networks," in *2018 International Conference on Computing, Networking and Communications (ICNC)*, 2018, pp. 815–821.
- [146] Z. Akhtar and T. H. Falk, "Audio-Visual Multimedia Quality Assessment: A Comprehensive Survey,"

- IEEE Access*, vol. 5, pp. 21090–21117, 2017.
- [147] D. Pal and V. Vanijja, “Effect of network QoS on user QoE for a mobile video streaming service using H.265/VP9 codec,” *Procedia Comput. Sci.*, vol. 111, pp. 214–222, 2017.
- [148] P. Gandotra, R. K. Jha, and S. Jain, “Sector-Based Radio Resource Allocation (SBRRA) Algorithm for Better Quality of Service and Experience in Device-to-Device (D2D) Communication,” *IEEE Trans. Veh. Technol.*, vol. 67, no. 7, pp. 5750–5765, 2018.
- [149] W. Zhou, Z. Wang, and W. Zhu, “Mining Urban WiFi QoS Factors: A Data Driven Approach,” *Proc. - 2017 IEEE 3rd Int. Conf. Multimed. Big Data, BigMM 2017*, pp. 9–16, 2017.
- [150] R. Boutaba *et al.*, “A comprehensive survey on machine learning for networking: evolution, applications and research opportunities,” *J. Internet Serv. Appl.*, vol. 9, no. 1, p. 16, Dec. 2018.
- [151] A. Floris, A. Ahmad, and L. Atzori, “QoE-Aware OTT-ISP Collaboration in Service Management: Architecture and Approaches,” *ACM Trans. Multimed. Comput. Commun. Appl.*, vol. 14, no. 2s, 2018.
- [152] A. Ahmad, A. Floris, and L. Atzori, “QoE-centric service delivery: A collaborative approach among OTTs and ISPs,” *Comput. Networks*, vol. 110, pp. 168–179, 2016.
- [153] O. Sahin, L. Thiele, and A. K. Coskun, “Maestro: Autonomous QoS Management for Mobile Applications under Thermal Constraints,” *IEEE Trans. Comput. Des. Integr. Circuits Syst.*, vol. 38, no. 8, pp. 1557–1570, 2019.
- [154] A. Ben Zineb, M. Ayadi, and S. Tabbane, “A novel cognitive architecture for QoS/QoE management in NextG Networks based on Q-learning and R-MLP approaches,” *2016 Int. Wirel. Commun. Mob. Comput. Conf. IWCMC 2016*, pp. 892–897, 2016.
- [155] A. A. Laghari, H. He, A. Khan, N. Kumar, and R. Kharel, “Quality of Experience Framework for Cloud Computing (QoC),” *IEEE Access*, vol. 6, no. 12, pp. 64876–64890, 2018.
- [156] H. Nourikhah and M. K. Akbari, “Impact of service quality on user satisfaction: Modeling and estimating distribution of quality of experience using Bayesian data analysis,” *Electron. Commer. Res. Appl.*, vol. 17, pp. 112–122, 2016.
- [157] N. Condori-Fernandez, “HAPPYNESS: An Emotion-Aware QoS Assurance Framework for Enhancing User Experience,” in *Proceedings of the 39th International Conference on Software Engineering Companion*, 2017, pp. 235–237.
- [158] M. S. Mushtaq, S. Fowler, B. Augustin, and A. Mellouk, “QoE in 5G cloud networks using multimedia services,” in *2016 IEEE Wireless Communications and Networking Conference*, 2016, pp. 1–6.
- [159] F. Volpato, M. P. Da Silva, A. L. Goncalves, and M. A. R. Dantas, “An autonomic QoE-aware management architecture for software-defined networking,” *Proc. - 2017 IEEE 26th Int. Conf. Enabling Technol. Infrastruct. Collab. Enterp. WETICE 2017*, pp. 220–225, 2017.
- [160] H. S. Chang, C. F. Hsu, T. Hoßfeld, and K. T. Chen, “Active Learning for Crowdsourced QoE Modeling,” *IEEE Trans. Multimed.*, vol. 20, no. 12, pp. 3337–3352, 2018.
- [161] A. J. Garcia, M. Toril, P. Oliver, S. Luna-Ramirez, and R. Garcia, “Big Data Analytics for Automated QoE Management in Mobile Networks,” *IEEE Commun. Mag.*, vol. 57, no. 8, pp. 91–97, 2019.
- [162] P. Latkoski, M. Porjazoski, and B. Popovski, “QoS control in OTT video distribution system,” in *IEEE EUROCON 2017 -17th International Conference on Smart Technologies*, 2017, pp. 99–103.
- [163] V. S. Elagin, I. A. Belozertsev, B. S. Goldshtein, A. V. Onufrienko, and A. G. Vladyko, “Models of QOE ensuring for OTT services,” *2019 Syst. Signals Gener. Process. F. Board Commun. SOSG 2019*, pp. 1–4, 2019.
- [164] X. Chen *et al.*, “Reinforcement learning-based QoS/QoE-aware service function chaining in software-driven 5G slices,” *Trans. Emerg. Telecommun. Technol.*, vol. 29, no. 11, pp. 1–18, 2018.
- [165] Q. Wang, H. N. Dai, H. Wang, and D. Wu, “Data-driven QoE analysis on video streaming in mobile networks,” *Proc. - 15th IEEE Int. Symp. Parallel Distrib. Process. with Appl. 16th IEEE Int. Conf. Ubiquitous Comput. Commun. ISPA/IUCC 2017*, pp. 1115–1121, 2018.
- [166] I. Orsolich, L. Skorin-Kapov, and T. Hosfeld, “To share or not to share? how exploitation of context data can improve in-network QoE monitoring of encrypted youtube streams,” *2019 11th Int. Conf. Qual. Multimed. Exp. QoMEX 2019*, 2019.

- [167] A. Martin *et al.*, "Network resource allocation system for QoE-aware delivery of media services in 5G networks," *IEEE Trans. Broadcast.*, vol. 64, no. 2, pp. 561–574, 2018.
- [168] J. Jiang, P. Spachos, M. Chignell, and L. Zucherman, "Assessing unreliability in OTT video QoE subjective evaluations using clustering with idealized data," *2016 Digit. Media Ind. Acad. Forum, DMIAF 2016 - Proc.*, pp. 235–239, 2016.
- [169] D. H. Fisher, "Knowledge Acquisition Via Incremental Conceptual Clustering," *Mach. Learn.*, vol. 2, no. 2, pp. 139–172, 1987.
- [170] E. Frank, M. A. Hall, and I. H. Witten, *The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques,"* 4th ed. 2016.
- [171] F. Guyard, M. Varela, L. Skorin-Kapov, A. Cuadra-Sanchez, and P. J. Sevilla-Ramos, "Quality of Experience Estimators in Networks," in *Quality of Experience Engineering for Customer Added Value Services*, Hoboken, NJ, USA: John Wiley & Sons, Inc., 2014, pp. 225–243.
- [172] ETSI TS 103 294, "Quality of Experience\_A Monitoring Architecture," 2014.
- [173] Cisco, "Cisco Annual Internet Report (2018–2023)," 2020.
- [174] R. Schatz *et al.*, "QoE Management for Future Networks," vol. 1, Springer International Publishing, 2018, pp. 49–80.
- [175] IETF, "Cisco Systems NetFlow Services Export Version 9 - RFC\_3954," 2004.
- [176] Group Nfdump, "Netflow processing tools." GitHub, 2021.
- [177] R. Hofstede *et al.*, "Flow monitoring explained: From packet capture to data analysis with NetFlow and IPFIX," *IEEE Commun. Surv. Tutorials*, vol. 16, no. 4, pp. 2037–2064, 2014.
- [178] IETF | Internet Engineering Task Force, "Specification of the IP Flow Information Export (IPFIX) Protocol for the Exchange of Flow Information - RFC\_7011," 2013.
- [179] CCNADESDECERO, "NetFlow: Funcionamiento y Configuración (Curso CCNA)," 2021. [Online]. Available: <https://ccnadesdecero.es/netflow-funcionamiento-configuracion/>. [Accessed: 01-Aug-2021].
- [180] Cisco Systems, "Implementing Quality of Service Policies with DSCP," 2008. [Online]. Available: <https://www.cisco.com/c/en/us/support/docs/quality-of-service-qos/qos-packet-marking/10103-dscpvalues.html>. [Accessed: 01-Aug-2021].
- [181] IETF, "Internet Protocol - RFC\_791," 1981.
- [182] IETF, "Definition of the Differentiated Services Field (DS Field) in the IPv4 and IPv6 Headers - RFC\_2474," 1998.
- [183] IETF, "Configuration Guidelines for DiffServ Service Classes-RFC\_4594," 2006.
- [184] ITU-T, "End-user multimedia QoS categories ITU-T G.1010," 2001.
- [185] J. Babiarz, K. Chan, and F. Baker, "Configuration Guidelines for DiffServ Service Classes - RFC 4594," 2006.
- [186] J. A. Caicedo-Muñoz, A. Ledezma Espino, J. C. Corrales, and A. Rendón, "QoS-Classifer for VPN and Non-VPN traffic based on time-related features," *Comput. Networks*, vol. 144, pp. 271–279, Oct. 2018.
- [187] Statistics Solutions, "Pearson's Correlation Coefficient," 2021. [Online]. Available: <https://www.statisticssolutions.com/free-resources/directory-of-statistical-analyses/pearsons-correlation-coefficient/>. [Accessed: 01-Aug-2021].
- [188] Statstutor team, "Spearman's correlation," 2011. [Online]. Available: <http://www.statstutor.ac.uk/resources/uploaded/spearmans.pdf>.
- [189] SciPy, "Statistical functions - Skew," *SciPy API Reference*, 2008. [Online]. Available: <https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.skew.html#scipy.stats.skew>.
- [190] Ubuntu 20-04\_TS, "Ubuntu Manpage: nfdump - netflow display and analyze program," 2019. [Online]. Available: <https://manpages.ubuntu.com/manpages/focal/man1/nfdump.1.html>. [Accessed: 01-Aug-2021].
- [191] ITU-T P.10/G.100 amd2, "Vocabulary for performance and quality of service," Geneva, 2008.
- [192] M. Fiedler, P. Reichl, and M. Xie, "QoE Vadis - Manifesto from Dagstuhl Perspectives Workshop 16472," *Dagstuhl Manifestos*, vol. 7, no. 1, pp. 30–51, 2018.
- [193] J. Brownlee, *Machine Learning Mastery with Python: Understanding your data, create accurate Models*

- and work projects end-to-end*. Machine Learning Mastery, 2020.
- [194] J. Brownlee, *Statistical Methods for Machine Learning: Discovery how to transform data into knowledge with python*. Machine Learning Mastery, 2019.
- [195] S. Ramírez-Gallego, B. Krawczyk, S. García, M. Woźniak, and F. Herrera, “A survey on data preprocessing for data stream mining: Current status and future directions,” *Neurocomputing*, vol. 239, pp. 39–57, 2017.
- [196] S. A. Alasadi and W. S. Bhaya, “Review of data preprocessing techniques in data mining,” *J. Eng. Appl. Sci.*, vol. 12, no. 16, pp. 4102–4107, 2017.
- [197] S. García, J. Luengo, and F. Herrera, *Data Preprocessing in Data Mining. Intelligent Systems Reference Library*, vol. 72, 320p. Cham: Springer International Publishing, 2015.
- [198] J. Brownlee, *Data Preparation for Machine Learning: Data cleaning, Feature selection, an data transform in Python*. Machine Learning Mastery, 2020.
- [199] Scikit Learn, “Mutual information - scikit-learn 0.24.2 documentation.” [Online]. Available: [https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_selection.mutual\\_info\\_regression.html#sklearn.feature\\_selection.mutual\\_info\\_regression](https://scikit-learn.org/stable/modules/generated/sklearn.feature_selection.mutual_info_regression.html#sklearn.feature_selection.mutual_info_regression). [Accessed: 01-Aug-2021].
- [200] NetworLessons, “IP Precedence and DSCP Values,” 2021. [Online]. Available: <https://networklessons.com/quality-of-service/ip-precedence-dscp-values>. [Accessed: 01-Aug-2021].
- [201] Scikit Learn, “Normalizer — scikit-learn 0.24.2 documentation.” [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.Normalizer.html>. [Accessed: 01-Aug-2021].
- [202] Operador de Telecomunicaciones - TIGO, “Planes pospago,” 2021. [Online]. Available: [https://compras.tigo.com.co/movil/pospago?\\_ga=2.241193415.457018992.1638364240-706939096.1608040246](https://compras.tigo.com.co/movil/pospago?_ga=2.241193415.457018992.1638364240-706939096.1608040246).
- [203] J. Brownlee, *Master Machine Learning Algorithms: Discovery how to they work and implement them from scratch*. Machine Learning Mastery, 2017.
- [204] Scikit Learn, “Linear Models — scikit-learn 0.24.2 documentation,” 2020. [Online]. Available: [https://scikit-learn.org/stable/modules/linear\\_model.html#linear-models](https://scikit-learn.org/stable/modules/linear_model.html#linear-models). [Accessed: 01-Aug-2021].
- [205] S. Rezaei and X. Liu, “How to Achieve High Classification Accuracy with Just a Few Labels: A Semi-supervised Approach Using Sampled Packets,” *arXiv Prepr. arXiv1812.09761*, Dec. 2018.
- [206] J. E. van Engelen and H. H. Hoos, “A survey on semi-supervised learning,” *Mach. Learn.*, vol. 109, no. 2, pp. 373–440, 2020.
- [207] V. Singhal, A. Gogna, and A. Majumdar, “Deep dictionary learning vs deep belief network vs stacked autoencoder: An empirical analysis,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9950 LNCS, pp. 337–344, 2016.
- [208] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning. Adaptive Computation and Machine Learning*, vol. 22, 775 p. Cambridge: Massachusetts, the MIT Press, 2017.
- [209] Medium Bootcamp AI, “Redes neuronales,” 2019. [Online]. Available: <https://bootcampai.medium.com/redes-neuronales-13349dd1a5bb>. [Accessed: 02-Aug-2021].
- [210] TensorFlow Core, “Regresion Basica: Predecir eficiencia de gasolina,” 2021. [Online]. Available: <https://www.tensorflow.org/tutorials/keras/regression?hl=es-419>. [Accessed: 02-Aug-2021].
- [211] Scikit Learn, “MLP Regressor — scikit-learn 0.24.2 documentation.” [Online]. Available: [https://scikit-learn.org/stable/modules/generated/sklearn.neural\\_network.MLPRegressor.html](https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPRegressor.html). [Accessed: 02-Aug-2021].
- [212] Scikit Learn, “Linear Regression — scikit-learn 0.24.2 documentation.” [Online]. Available: [https://scikit-learn.org/stable/modules/generated/sklearn.linear\\_model.LinearRegression.html](https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LinearRegression.html). [Accessed: 02-Aug-2021].
- [213] Scikit Learn, “Ridge — scikit-learn 0.24.2 documentation.” [Online]. Available: [https://scikit-learn.org/stable/modules/generated/sklearn.linear\\_model.Ridge.html](https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.Ridge.html). [Accessed: 02-Aug-2021].
- [214] Scikit Learn, “Lasso — scikit-learn 0.24.2 documentation.” [Online]. Available: [https://scikit-learn.org/stable/modules/generated/sklearn.linear\\_model.Lasso.html](https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.Lasso.html). [Accessed: 02-Aug-2021].
- [215] Scikit Learn, “ElasticNet — scikit-learn 0.24.2 documentation.” [Online]. Available: [https://scikit-learn.org/stable/modules/generated/sklearn.linear\\_model.ElasticNet.html](https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.ElasticNet.html).

- learn.org/stable/modules/generated/sklearn.linear\_model.ElasticNet.html. [Accessed: 02-Aug-2021].
- [216] Scikit Learn, “KNeighbors Regressor — scikit-learn 0.24.2 documentation.” [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsRegressor.html>. [Accessed: 02-Aug-2021].
- [217] Scikit Learn, “Decision Tree Regressor — scikit-learn 0.24.2 documentation.” [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.tree.DecisionTreeRegressor.html>. [Accessed: 02-Aug-2021].
- [218] Scikit Learn, “SVR — scikit-learn 0.24.2 documentation.” [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVR.html>. [Accessed: 02-Aug-2021].
- [219] Scikit Learn, “MinMaxScaler — scikit-learn 0.24.2 documentation.” [Online]. Available: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html>. [Accessed: 02-Aug-2021].
- [220] SciPy, “Two-sample Kolmogorov-Smirnov test — SciPy v1.7.1 Manual.” [Online]. Available: [https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.ks\\_2samp.html#id1](https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.ks_2samp.html#id1). [Accessed: 02-Aug-2021].
- [221] J. De Leeuw, “Computing the Two-Sided Kolmogorov-Smirnov Distribution,” *Wiley Interdiscip. Rev. Comput. Stat.*, vol. 1, no. 1, pp. 128–129, 2009.
- [222] K. Mitra, A. Zaslavsky, and C. Åhlund, “QoE Modelling, Measurement and Prediction: A Review,” pp. 1–25, arXiv preprint arXiv:1410.6952, 2014.
- [223] K. Nichols and S. Blake, “Definition of the Differentiated Services Field (DS Field) in the IPv4 and IPv6 Headers. RFC 2474,” 1998.
- [224] Internet Assigned Numbers Authority (IANA), “Differentiated Services Field Codepoints (DSCP).” [Online]. Available: <https://www.iana.org/assignments/dscp-registry/dscp-registry.xhtml>.
- [225] Scikit Learn, “Tuning the hyper-parameters of an estimator,” 2007. [Online]. Available: [https://scikit-learn.org/stable/modules/grid\\_search.html](https://scikit-learn.org/stable/modules/grid_search.html).
- [226] Scikit Learn, “Ada Boost Regressor - scikit-learn 1.0.1 documentation,” 2007.
- [227] ITU-T P.10/G.100, “Vocabulary for performance, quality of service and quality of experience,” 2017.

## ANEXOS

### ANEXO A. APLICACIÓN QOE\_MOS

#### A.1. DESCRIPCIÓN GENERAL DE LA APLICACIÓN QOE\_MOS

La Figura A.1.1 presenta los procesos generales de la aplicación QoE-MOS para la captura de datos de percepción de la calidad en relación con el consumo de servicios de internet durante una sesión de navegación de un usuario.

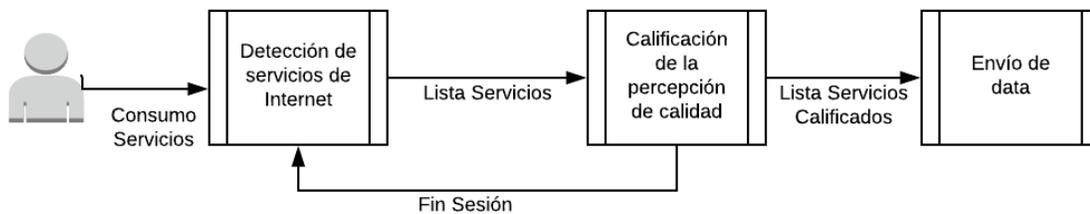


Figura A.1.1. Procesos de la aplicación QoE\_MOS

El flujo de interacción de la aplicación es el siguiente:

- Un usuario inicia el navegador de su preferencia y consume servicios de internet.
- El proceso de *Detección de servicios de Internet* monitoriza continuamente si existe una sesión activa en un navegador y el cierre de la sesión. Una vez se termine el consumo de servicios de internet, este proceso envía una lista de los servicios consumidos durante la sesión activada de navegación por parte del usuario.
- El proceso de *Calificación de la percepción de la calidad* despliega la lista de servicios consumidos por el usuario para que este proceda con la calificación según métrica MOS (Mean Opinion Score).
- Una vez el usuario realiza la calificación de percepción de calidad de los servicios consumidos durante la sesión o duración de la navegación, el proceso de calificación lista de servicios con su respectiva evaluación.
- Finalmente, la lista de servicios calificados es enviada a un nodo recolector para el registro y procesamiento de información. Esta tarea es llevada a cabo por el proceso de *Envío de data*.

Finalmente, la Tabla A.1.1 presenta el formato general de las salidas de cada uno de los procesos de la aplicación.

Tabla A.1.1 Formato de las salidas de los procesos de QoE\_MOS.

Proceso	Salida	Formato
Detección de servicios de internet	Lista Servicios	listDepurada = [DominioA, DominioB]  e.g. listDepurada = [Facebook.com, Youtube.com]

Calificación de la percepción de la calidad	Lista Servicios Calificados	<pre>listSerQ = [(DominioA, scoreA), (DominioB, scoreB), {timeON: MM/DD/AA hh:mm:ss, timeOFF: MM/DD/AA hh:mm:ss }]</pre> <p><b>e.g.</b> listSerQ = [(Facebook, 3), (Youtube, 4), {timeON: 24/10/18 11:11:11, timeOFF: 24/10/18 11:12:11}]</p>
---	-----------------------------	---

## A.2. PROCESOS DE LA APLICACIÓN QOE\_MOS

Cada uno de los procesos de la aplicación QoE\_MOS tienen un conjunto de funciones con tareas específicas que permiten su correcto funcionamiento. La Figura A.2.1 ilustra las funciones de cada uno de los procesos que fueron definidas y desarrolladas para la aplicación.

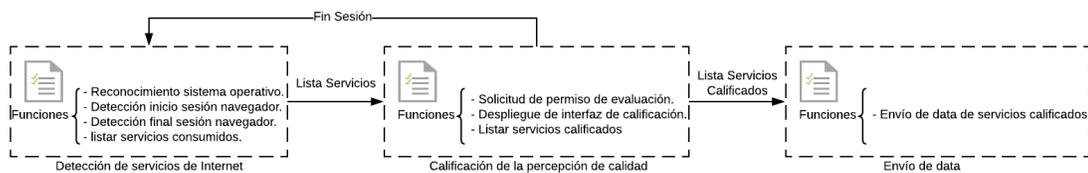


Figura A.2.1. Funciones de los procesos de la aplicación QoE\_MOS.

### 2.1. Proceso de detección de servicios de internet

La Figura A.2.2 presenta el flujo de ejecución de las funciones que componen el proceso de detección de servicios de Internet.

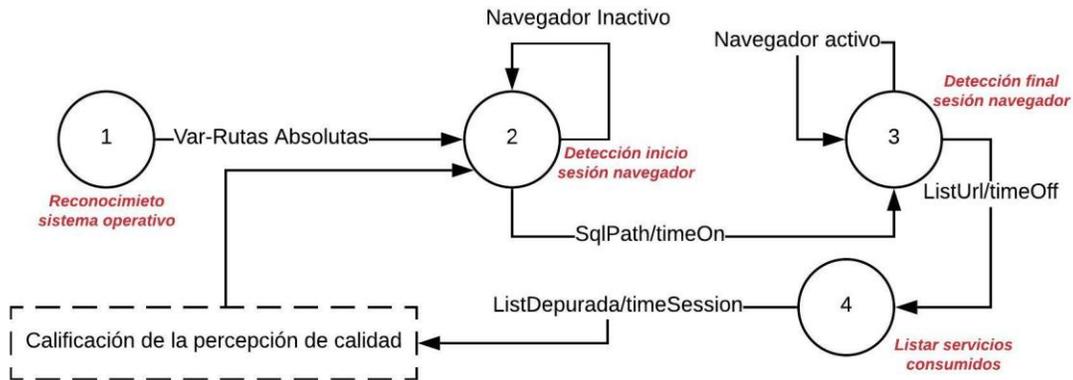


Figura A.2.2. Flujo de ejecución de las funciones del proceso de detección de servicios de Internet.

El proceso de detección de servicios de Internet inicia con la función de *Reconocimiento sistema operativo* (1), la cual tiene la tarea de detectar en qué sistema operativo el usuario está activo. De igual manera, esta función define las variables absolutas y de las rutas de acceso a los navegadores instalados en los equipos (i.e Chrome, Chromium, Firefox).

La función *Detección inicio sesión navegador* (2) monitoriza continuamente si el usuario ha iniciado sesión en el navegador de su preferencia; una vez el usuario inicia la navegación de Internet, esta función lleva a cabo

tareas como: obtener la ruta absoluta del archivo SQLite que almacena el historial de navegación (i.e. SqlPath), y definir el inicio del tiempo de la sesión activa de navegación del usuario (i.e. timeOn).

La función *Detección final sesión navegador* (3) monitoriza continuamente si el usuario ha terminado sesión en el navegador de su preferencia; una vez el usuario termina la navegación de Internet, esta función lleva a cabo tareas como: definir el final del tiempo de la sesión activa de navegación del usuario (i.e. timeOff); obtener la sentencia SQLite de consulta para el historial de navegación durante el tiempo de sesión activa; obtener los resultados de la consulta debidamente parametrizada; y listar los dominios visitados durante la sesión activa de navegación con sus respectivos tiempos de visita y duración (i.e. ListUrl).

La función *Listar servicios consumidos* (4) presenta una lista de tuplas organizadas de los servicios de mayor consumo durante la sesión activa de navegación del usuario. Para ello, se llevan a cabo tareas específicas, a saber: obtener una lista ordenada por tiempo de mayor consumo de los dominios visitados durante la sesión activa de navegación (i.e. ListDepurada); y parametrizar la llamada al proceso de calificación de la percepción de calidad (i.e ListDepurada, timeSession)

Es importante resaltar que la lista ordenada por tiempo de consumo de cada dominio fue restringida a 5 servicios para su calificación y definida de acuerdo con las condiciones del tiempo de visita presentes en el historial de cada navegador.

La Tabla A.2.1 presenta un resumen de las funciones con sus respectivas tareas e implementaciones para el proceso de detección de servicios de Internet.

**Tabla A.2.1.** Resumen de funciones del proceso de detección de servicios de Internet.

Función	Tarea	Implementación	Observaciones
Reconocimiento sistema operativo (1)	Detectar sistema operativo.	Windows o Linux	Las variables definidas según el sistema operativo.
	Definir variables y rutas absolutas	Chomre: path por defecto del historial Firefox: path por defecto del historial Chromium: path por defecto del historial	El path depende del sistema operativo.
Detección inicio sesión navegador (2)	Obtener ruta del SQLite del historial	get_path(opeSystem, browserPath)	Depende de las variables absolutas definidas.
	Definir tiempo de inicio de navegación	timeSession['timeON']	
Detección final sesión navegador (3)	Definir tiempo final de la navegación	timeSession['timeOFF']	
	Obtener sentencia SQLite	get_sql(BRW, timeOn, timeOff)	
	Obtener resultados de la consulta	get_domain(sqlite_path,select_statement)	
	Listar dominios visitados	listUrl	

Listar servicios consumidos (4)	Obtener lista ordenada por tiempo.	lista por	get_time_service_firefox(listSQL) get_time_service_chrome(listSQL, timeOff)	Firefox y Chrome manejan tiempos de visita diferentes. No presente en Firefox
	Parametrizar llamada al proceso de calificación	al de	QoEGUI.simpleapp_tk(None, listDepurada, timeSession)	

## 2.2. Proceso de calificación de la percepción de calidad

La Figura A.2.3 presenta el flujo de ejecución de las funciones que componen el proceso de calificación de la percepción de calidad.

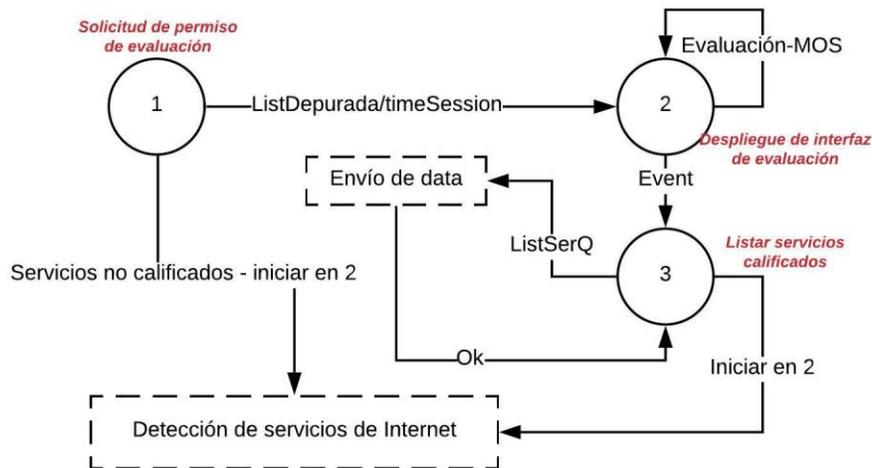


Figura A.2.3. Flujo de ejecución de las funciones del proceso de calificación de la percepción de calidad.

El proceso de calificación de la percepción de calidad inicia con la función de *Solicitud de permiso de evaluación* (1), la cual tiene la tarea de preguntar al usuario si desea realizar la calificación de los servicios de internet consumidos durante su sesión del navegador. En caso de no aceptar, el proceso de detección de servicios de Internet es activado en su función dos (2) mientras el proceso de calificación de la percepción de calidad es terminado (i.e. Servicios no calificados – iniciar en 2). En caso de aceptar la evaluación de la calidad de los servicios de Internet, la tarea de iniciar la interfaz gráfica es ejecutada con los parámetros respectivos (i.e. ListDepurada/timeSession).

La función *Despliegue de interfaz de calificación* (2) expone una interfaz donde se encuentran listados los servicios más consumidos durante la sesión activa de navegación. Para ello, se ejecutan tareas específicas, a saber: visualizar los servicios consumidos (máximo 5) y la escala de puntuación según la percepción de calidad absoluta definida por la ITU-T en su recomendación P.800.1 (i.e. Evaluación-MOS); y activar opción de envío de servicios calificados (i.e. Event).

La función *Listar servicios calificados* (3) define una lista de los servicios con la respectiva calificación otorgada por el usuario. Las tareas ejecutadas son: listar los servicios calificados (i.e. ListSerQ); parametrizar la llamada

al proceso de envío de data; e iniciar la función dos (2) del proceso de detección de servicios de Internet (i.e. iniciar en 2).

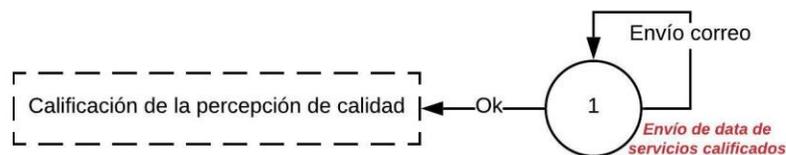
La Tabla A.2.2 presenta un resumen de las funciones con sus respectivas tareas e implementaciones para el proceso de calificación de la percepción de calidad.

**Tabla A.2.2.** Resumen de funciones del proceso de calificación de la percepción de calidad.

Función	Tarea	Implementación	Observaciones
Solicitud de permiso de evaluación (1)	Preguntar al usuario.	Mensaje con respuesta de sí o no	
	Iniciar interfaz de calificación.	self.initialize(listSer,timeSession)	En caso de aceptar evaluar los servicios de Internet consumidos
Despliegue interfaz de calificación (2)	Visualizar servicios consumidos y escala MOS.	initialize(self, services,timeSession)	La interfaz se mantiene activa mientras el usuario realiza la calificación.
	Activar opción de envío de servicios calificados.	command=self.OnButtonSend	Implementado en botón 'Enviar' de la interfaz
Listar servicios calificados (3)	Listar servicios calificado.	OnButtonSend(self) get_MOS_values(self)	Se obtiene la lista de servicios calificados más el tiempo de sesión de navegación del usuario debidamente ajustado a formato fecha
	Parametrizar la llamada al proceso de envío de data.	Email.sendmail(listSerQ)	
	Iniciar función 2 del proceso de detección de servicios de Internet.	self.destroy()	

### 2.3. Proceso de envío de data

La Figura A.2.4 presenta el flujo de ejecución de las funciones que componen el proceso de envío de data.



**Figura A.2.4.** Flujo de ejecución de las funciones del proceso de envío de data.

El proceso de envío de data inicia con la función *Envío de data de servicios calificados* (1), la cual tiene la tarea de estructurar el formato de correo para su respectivo envío.

La Tabla A.2.3 presenta un resumen de las funciones con sus respectivas tareas e implementaciones para el proceso de envío de data.

Tabla A.2.2. Resumen de funciones del proceso de envío de data.

Función	Tarea	Implementación	Observaciones
Envío de data de servicios calificados (1)	Estructurar formato de correo.	sendmail (listSerQ)	Se envía a dos cuentas de correo.

### A.3. IMPLEMENTACIÓN DE LOS PROCESOS DE LA APLICACIÓN QOE\_MOS

La Figura A.3.1 presenta la implementación de los procesos de la aplicación QoE\_MOS.

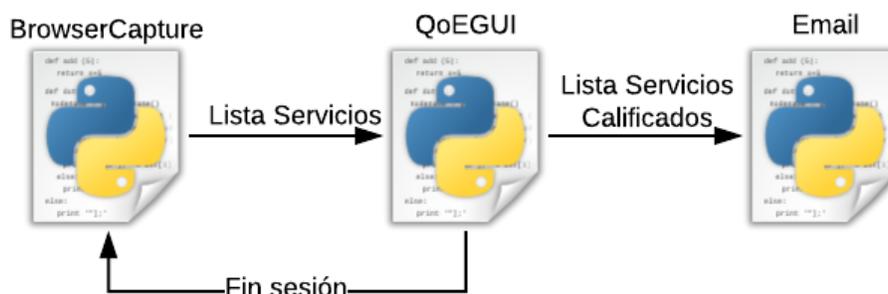


Figura A.3.1. Implementación de los procesos QoE\_MOS.

La implementación de cada proceso es la siguiente:

- Script BrowserCapture implementa el proceso de detección de servicios de Internet.
- Script QoEGUI implementa el proceso calificación de la percepción de calidad.
- Script Email implementa el proceso de envío de data.

Finalmente, las figuras A.3.2, A.3.3, y A.3.4 presentan una captura de la solicitud de evaluación, de la interfaz de calificación, y del formato de los servicios calificados enviado para procesamiento, respectivamente.

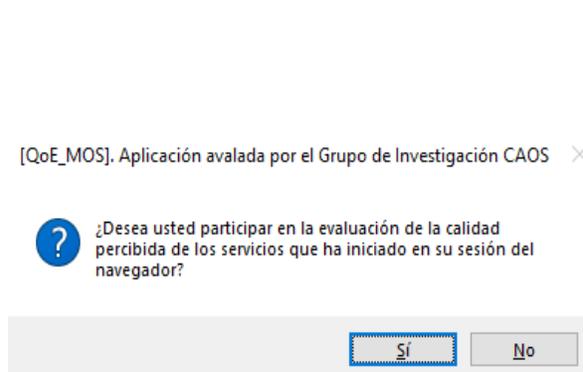


Figura A.3.2. Solicitud de permiso de evaluación.

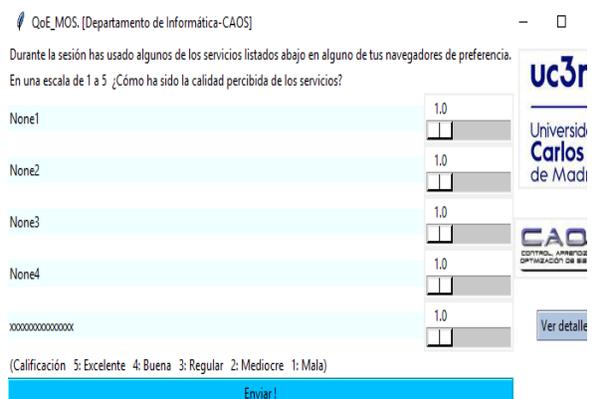


Figura A.3.3. Interfaz de calificación según métrica MOS.



a0370770@lab.inf.uc3m.es

[('www.youtube.com', '1.0'), ('www.google.es', '1.0'), {'timeON': '10/22/18 10:49:44', 'timeOFF': '10/22/18 10:50:06'}]

lun., 22 oct. 11:50 (hace 1

**Figura A.3.4.** Formato de servicios calificados.

## ANEXO B. PROTOCOLO CONCEPTUAL

### B.1. ANTECEDENTES

El modelo correlacional QoS-QoE pretende definir un mecanismo que relacione la Calidad del Servicio (QoS, Quality of Service) en la prestación de un servicio de comunicaciones con la Calidad de Experiencia (QoE, Quality of Experience) de un usuario toda vez que este haya consumido el servicio. Para ello, el modelo contará con técnicas de inteligencia artificial y de aprendizaje automático con el ánimo de estimar-predecir un valor o nivel adecuado en la QoE para un conjunto de usuarios clasificados, inicialmente, por su comportamiento de consumo; en consecuencia, una Telco podrá contar con un insumo para tomar decisiones a nivel técnico, tecnológico, y de negocio que propendan por el mejoramiento de la QoS de los servicios entregados al usuario final.

En resumen, el modelo correlacional QoE-QoS estudia la QoE en el aprovisionamiento de servicios OTT bajo condiciones o criterios de QoS en el dominio del operador telecomunicaciones. Para ello, se ha propuesto un modelo QoE para servicios OTT, donde sus dos primeras iteraciones consisten en la obtención del mapa estratégico que relaciona la QoE con la QoS y los servicios OTT, y la segunda, una definición de los elementos conceptuales que dan estructura y contenido al modelo.

Teniendo en cuenta lo anterior, este protocolo establece las directrices generales para el desarrollo de las dos primeras iteraciones del modelo QoE para servicios OTT.

### B.2. PREGUNTAS DE BÚSQUEDA

Las preguntas que conducen el mapeo del estado de la ciencia alrededor de la QoE se dividen en dos partes. La primera, establece las preguntas generales que orientan el análisis de la evolución y relevancia científica (i.e. etapa SM-1 del modelo); la segunda, define las preguntas específicas que orientan el análisis de los elementos constituyentes del modelo (i.e. etapa SLR-1 del modelo). Los elementos constituyentes deben ser uno de los resultados de la etapa SM-5 del modelo.

#### Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT

- ¿Cuál ha sido la evolución en la ciencia alrededor de la QoE en la prestación de servicios OTT?
- ¿Qué temas específicos de investigación están siendo atendidos alrededor de la QoE para servicios OTT?
- ¿Quiénes son los autores más relevantes alrededor de la QoE?
- ¿Cuáles son los desafíos o limitaciones alrededor de la QoE en el aprovisionamiento de servicios OTT?
- 

#### Parte 2: Análisis de los elementos constituyentes del modelo

- ¿Cuáles son los elementos conceptuales del modelo de QoE para Servicios OTT?
- ¿Qué características esenciales posee cada elemento conceptual del modelo?
- ¿Qué modelos o técnicas de aprendizaje son empleadas para en el estudio de las características de los elementos conceptuales del modelo?

- ¿Qué métricas de evaluación son consideradas para cada uno de los elementos conceptuales?

La Tabla B.2.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.2.1.** Relación de etapas del modelo QoE para OTT con las preguntas de búsqueda

Etapas del modelo	
Iteración 1- SM	Iteración 2: SLR
SM-1	SLR-1

### B.3. PROCESO DE BÚSQUEDA

El proceso de búsqueda de la información en relación con el campo de estudio (i.e. QoE) se realiza de manera manual en librerías digitales reconocidas y relacionadas con el área general de conocimiento (i.e. ingeniería). Adicionalmente, se consulta literatura técnica de organismos de control y regulación, y se obtiene información de expertos en el tema; esto es:

#### Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT

Lista de fuentes:

- Web of Science
- IEEE Xplore (<https://ieeexplore.ieee.org/Xplore/home.jsp>)
- ACM Digital Library (<https://dl.acm.org/>)
- Science Direct (<https://www.sciencedirect.com/>)
- Scopus (<https://www.scopus.com/home.uri>)
- BASE (<https://www.base-search.net/>)
- Wiley Online Library (<https://onlinelibrary.wiley.com/>)
- Springer Link (<https://link.springer.com/>)

La lista particular ha sido tomada según los resultados del estudio sobre los sistemas de búsqueda académicos más apropiados para desarrollar revisiones sistemáticas o metaanálisis. Para conocer más del estudio y de los sistemas de búsqueda académicos analizados referirse a [62].

Para efectos de la recolección y agrupación de la documentación, se procede así:

- La cadena de búsqueda a ejecutar es: “Quality of Experience” OR “QoE”. Dependiendo del motor de búsqueda, la configuración de la cadena de consulta puede variar (Producto de la etapa SM-2 del modelo).
- Presentar la cantidad de artículos por base de datos científica (Producto de la etapa SM-2 del modelo)
- Refinar la cadena de búsqueda de acuerdo con la pertinencia de los estudios; esto es: (“Quality of Experience” OR “QoE”) AND (QoS OR OTT).
- Exportar el archivo total de estudios encontrados en cualquiera de los siguientes formatos: RIS, WoS, CVS.

#### Parte 2: Análisis de los elementos constituyentes del modelo

Lista de fuentes:

- Organismos de estandarización internacional (e.g. ITU-T, ETSI, IETF, TMF, 3GPP).

- Organismos de control y regulación nacional (e.g. CRC - MinTIC)
- Expertos en la temática.

Para efectos de la recolección y agrupación de la documentación, se procede así:

- La cadena de búsqueda a ejecutar en bases de datos de los organismos de estandarización es: (Quality of Experience OR QoE), (Quality of Service OR QoS), “Perceived Quality”, OTT OR Provisioning (“OTT provisioning”), Machine learning.
- Presentar la cantidad de documentos recuperados por organismo internacional y nacional de estandarización y regulación.
- Agrupar las reflexiones de expertos bajo la etiqueta de documentación de apoyo y toma de decisiones.
- Presentar la cantidad de artículos objeto de análisis detallado que resulten de la síntesis de la etapa SM-5 del modelo

La Tabla B.3.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.3.1.** Relación de etapas del modelo QoE para OTT con el proceso de búsqueda

Etapas del modelo	
Iteración 1- SM SM-2	Iteración 2: SLR SLR-2A y SLR-2B

## B.4. CRITERIOS DE SELECCIÓN DE ESTUDIOS

Los criterios de selección de artículos se definen con el ánimo de determinar qué estudios serán incluidos o excluidos de la revisión; esto es:

### Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT

#### Criterios de inclusión.

- Publicaciones científicas a partir del año 2000 en adelante.
- La ventana de observación debe ser por lo menos de mínimo 10 años.
- Las publicaciones científicas comprenden: libros, capítulos de libros, journals y magazines, conferencias, y artículos de datos.
- Publicaciones científicas que abarquen el modelado, medición, gestión, aprovisionamiento y estimación de la QoE.

#### Criterios de exclusión.

- Literatura gris y técnica especializada (e.g. cursos, videos, trabajos de opinión)
- Publicaciones científicas sin citas (no aplica para estudios con 4 años antes del inicio de la revisión)
- Publicaciones científicas en su versión no extendida para documentos duplicados.

### Parte 2: Análisis de los elementos constituyentes del modelo

**Criterios de inclusión.**

- Normatividad internacional y nacional en relación con la gestión de la QoE, aprovisionamiento de QoS en redes 4G/5 G, y despliegue de servicios OTT en una Telco.
- Disertaciones de expertos en temas de QoE, QoS, y OTT desarrolladas en foros, memorias de seminarios, y artículos de reflexión.

**Criterios de exclusión.**

- Normatividad en estudio o no vigente.

La Tabla B.4.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.4.1.** Relación de etapas del modelo QoE para OTT con los criterios de selección de los estudios

Etapas del modelo	
Iteración 1- SM	Iteración 2: SLR
SM-3	SLR-2B

**B.5. PROCEDIMIENTO DE SELECCIÓN DE ESTUDIOS**

El proceso de selección de los estudios se realizará con base en los criterios de inclusión y exclusión, criterios de calidad de los estudios (e.g. métrica de impacto), y de la estrategia del cuadrante [64]; esto es:

**Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT**

- a) Cargar en la herramienta SciMAT los archivos exportados de las referencias obtenidos de la ejecución de cadena de búsqueda.
- b) Aplicar los criterios de inclusión y exclusión.
- c) Aplicar el criterio de calidad para los estudios de la siguiente manera: clasificar estudios por número de publicaciones, por periodo de análisis, y por categoría y relación conceptual.
- d) Ejecutar los procesos de preprocesamiento y extracción de la red expuestos por M.J. Cobo et al., en [63]

**Parte 2: Análisis de los elementos constituyentes del modelo**

- a) Aplicar los criterios de inclusión y exclusión.
- b) Aplicar el criterio de calidad para los estudios de la siguiente manera:
  - Para los estudios objeto de análisis detallado, realizar la clasificación según elementos constituyentes del modelo y ponderarlos por relevancia. La relevancia se toma a partir del resultado del proceso de *mapping* expuesto por M.J. Cobo et al., en [63].
  - Para las especificaciones de los organismos de estandarización y normalización, organizarlos de acuerdo con el año de vigencia de manera descendente.
  - Para las reflexiones de expertos, organizarlas por cantidad por año, por relevante por año, y por seleccionado por año. La relevancia se estima con base en el contexto donde fue presentada y por trayectoria del expositor.

La Tabla B.5.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.5.1.** Relación de etapas del modelo QoE para OTT con el procedimiento de selección de los estudios

Etapas del modelo	
Iteración 1- SM SM-3	Iteración 2: SLR SLR-2B

## B.6. EVALUACIÓN DE CALIDAD

La evaluación de calidad permite ponderar la relevancia y pertenencia de los estudios hallados; esto es:

### Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT

- Resultado del proceso de extracción de la red expuesto en [63].
- Clasificación de artículos por el número de citas con alto impacto.

### Parte 2: Análisis de los elementos constituyentes del modelo

- Para los estudios objeto de análisis detallado, la relevancia se toma a partir del resultado del proceso de *mapping* expuesto por M.J. Cobo et al., en [63].
- Para las especificaciones de los organismos de estandarización, la relevancia está dada por su año de vigencia.
- Para las reflexiones de los expertos, la relevancia está dada por el contexto donde fue presentada y por la trayectoria del expositor. El contexto de la presentación recibe una ponderación de Alta (5), media (3) y baja calidad (1), dependiendo del reconocimiento del evento; la trayectoria del expositor recibe una ponderación de Alta (5), media (3), y baja calidad (1), dependiendo de la experticia del expositor.
- La pertinencia de los estudios o reflexiones está orientada a la calidad del contenido; esto es: ¿Resuelve con claridad las preguntas de búsqueda? ¿Tiene la información suficiente para reproducir los experimentos? ¿El conjunto de datos está disponible? ¿Qué factores de influencia en la QoE son considerados en la estimación?
- Definir un índice de calidad absoluto para computar la relevancia y pertinencia de los estudios. La Pertinencia está relacionada con el tema, es decir, que tenga una relación directa (i.e. relación de contenido) con la categoría conceptual definida. La relevancia se centra en el nivel de importancia en el tema (e.g. número de citas)

La Tabla B.6.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.6.1.** Relación de etapas del modelo QoE para OTT con la evaluación de la calidad de los estudios

Etapas del modelo	
Iteración 1- SM SM-4	Iteración 2: SLR SLR-2B

## B.7. ESTRATEGIA DE EXTRACCIÓN DE DATOS

Para la extracción de los datos de los estudios encontrados, preprocesados, y ponderados, se procede así:

### Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT

- La extracción de los datos se realiza teniendo en cuenta el proceso de *mapping* y análisis expuesto por M.J. Cobo et al., en [63].

## Parte 2: Análisis de los elementos constituyentes del modelo

- Se genera una matriz de trabajos indicando su grado de relevancia y pertinencia.
- La matriz debe especificar qué datos obtener de cada trabajo seleccionado para el análisis; es decir, definir las características esenciales de los elementos constituyentes.

La Tabla B.7.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.7.1.** Relación de etapas del modelo QoE para OTT con la estrategia para extracción de los datos

Etapas del modelo	
Iteración 1- SM	Iteración 2: SLR
SM-5	SLR-2C

## B.8. SÍNTESIS DE LOS DATOS EXTRAÍDOS

La síntesis de los datos de los estudios se realiza a través del proceso de metaanálisis; esto es:

### Parte 1: Análisis de la evolución científica en el marco de la QoE para servicios OTT

- Ejecución del proceso de visualización e interpretación expuesto por M.J. Cobo et al., en [63].
- Diagrama de visualización de resultados (e.g. cuadrante de temas [64], burbujas por categoría conceptual)

### Parte 2: Análisis de los elementos constituyentes del modelo

- Se presenta una clasificación ponderada por elemento constituyente del modelo.
- Se realiza la síntesis descriptiva de los datos extraídos de los elementos conceptuales del modelo.

La Tabla B.8.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.8.1.** Relación de etapas del modelo QoE para OTT con la síntesis de los datos

Etapas del modelo	
Iteración 1- SM	Iteración 2: SLR
SM-5	SLR-2D

## B.9. PRESENTACIÓN

La presentación del resultado del estado de la ciencia en el aprovisionamiento de la QoE para servicios OTT bajo condiciones de QoS en el dominio del operador, debe ser sometida a revisión científica por parte de un comité evaluador o de validación por parte de la Telco. En ese sentido, se debe exponer un listado de revistas potenciales para publicación.

La Tabla B.9.1 presenta relaciona las etapas del modelo QoE para servicios OTT con la sección del protocolo conceptual.

**Tabla B.9.1.** Relación de etapas del modelo QoE para OTT con la presentación de los resultados

<b>Etapas del modelo</b>	
Iteración 1- SM	Iteración 2: SLR
NA	SLR-3