

Mecanismo para el control de admisión de llamadas soportado en técnicas de aprendizaje automático.



**Leidy Katherine Casilimas López
Nancy Yamileth Cifuentes Rosero**

**Monografía presentada como requisito para optar por el título de
Ingeniero en Electrónica y Telecomunicaciones**

Director: PhD. Juan Carlos Corrales Muñoz

Universidad del Cauca

Facultad de Ingeniería Electrónica y Telecomunicaciones

Departamento de Telemática

Línea de Investigación en Ingeniería de Sistemas Telemáticos

Popayán, enero de 2018

Leidy Katherine Casilimas López
Nancy Yamileth Cifuentes Rosero

Mecanismo para el control de admisión de llamadas
soportado en técnicas de aprendizaje automático

Trabajo de grado presentado en la Facultad de
Ingeniería Electrónica y Telecomunicaciones de la
Universidad del Cauca para la obtención del Título de

Ingeniero en:
Electrónica y Telecomunicaciones

Director:
Juan Carlos Corrales Muñoz
PhD. en Ciencias de la Computación

Popayán 2018

Contenido

1	Capítulo: Introducción	1
1.1	Contexto	1
1.2	Motivación	1
1.3	Definición del problema.....	2
1.4	Objetivos	3
1.4.1	Objetivo General.....	3
1.4.2	Objetivos Específicos.	3
1.5	Contribuciones	4
2	Capítulo: Estado del arte	5
2.1	Contexto general.....	5
2.1.1	Voz sobre protocolo de internet – VoIP	5
2.1.2	Calidad de servicio – QoS	7
2.1.3	Aprendizaje automático – ML	9
2.1.4	Control de admisión de llamadas - CAC.....	10
2.2	Antecedentes	10
3	Capítulo: Construcción del conjunto de datos.....	19
3.1	Generación de datos.....	19
3.1.1	Descripción y herramientas (Asterisk-DITG-Wireshark-Sipp).....	20
3.2	Construcción del conjunto de datos	29
3.3	Descripción del conjunto de datos	38
3.3.1	Fase 1 CRISP-DM: Comprensión del negocio.....	38
3.3.2	Fase 2: Comprensión de los datos	39
3.4	Fase 3: Preparación de los datos.....	44
3.4.1.5	Balanceo de clases.....	52
4	Capítulo: Modelado.....	55

4.1.1	Selección de la técnica de modelado	55
4.1.2	Generación del plan de prueba.	55
4.1.3	Comprensión de los resultados obtenidos.....	64
5	Capítulo: Definición de políticas.....	68
5.1	Definición SLA.....	68
5.1.1	Tipo de SLA (Nivel de servicio).....	69
5.1.2	Definición de política.....	71
	Especificaciones de Nivel de Servicio (ENS) que en conjunto constituyen el Acuerdo de Nivel de servicio (ANS) [3].....	71
6	Capítulo: Conclusiones y trabajos futuros.....	77
6.1	Conclusiones.....	77
6.2	Trabajos futuros	79
7	Referencias.....	81
	Anexo A.....	89

ÍNDICE DE FIGURAS.

Figura 2-1. Protocolos IP.....	6
Figura 2-2. Trabajos relacionados por año.....	11
Figura 2-3. Distribución de los trabajos relacionados por capas NGN.	12
Figura 2-4. Número de artículos por algoritmo usados en la capa de transporte. .	12
Figura 2-5. Número de artículos por algoritmo usados en la capa de capa de servicio.	13
Figura 2-6. Número de artículos por algoritmo usados en la capa de control.	14
Figura 2-7. Número de artículos por algoritmo usados en la capa de acceso.....	14
Figura 3-1. Protocolos importantes en la construcción del conjunto de datos.....	19
Figura 3-2. Esquema general del escenario de prueba.....	29
Figura 3-3. Escenario de prueba.	30
Figura 3-4. Número de intentos de llamada frente a llamadas establecidas.	32
Figura 3-5. Comportamiento de las llamadas con duración promedio.	33
Figura 3-6. Comprensión del negocio.	¡Error! Marcador no definido.
Figura 3-7. Proceso de comprensión de los datos.	39
Figura 3-8. Proceso de preparación de los datos.....	44
Figura 3-9. Eliminación de valores atípicos.....	47
Figura 3-10. Proceso de generación de grupos.	48
Figura 3-11. Árbol de decisión para el algoritmo de agrupamiento con $k=3$	50
Figura 3-12. Comparación entre grupos aplicando K-Means y los etiquetados con REC-Y.1541.	52
Figura 5-1. Arquitectura del sistema.....	68
Figura 5-2. Servicios ofrecidos.	70
Figura 5-3. Definición de políticas.	71
Figura 5-4. Escenario ejemplo: Campus universitario.	73
Figura 5-5. Servicio oro: Usuarios, requerimientos y políticas.....	74
Figura 5-6. Servicio plata: Usuarios, requerimientos y políticas.....	75
Figura 5-7. Servicio bronce: Usuarios, requerimientos y políticas.....	76

ÍNDICE DE TABLAS.

Tabla 2-1. Principales códecs de VoIP.	7
Tabla 2-2. Clasificación de los trabajos relacionados.	15
Tabla 2-3. Brechas	17
Tabla 3-1. Comparación de centrales de VoIP.	22
Tabla 3-2. Comparación de generadores de tráfico.	24
Tabla 3-3. Comparación de generadores de llamadas.	26
Tabla 3-4. Comparación herramientas de monitoreo.	29
Tabla 3-5. Características equipos.	30
Tabla 3-6. Parámetros comando Sipp.	31
Tabla 3-7. Prueba variando la duración de llamada.	33
Tabla 3-8. Moda de cada parámetro con respecto a la duración de llamada.	34
Tabla 3-9. Media de los parámetros con respecto a la duración de llamada.	35
Tabla 3-10. Dimensionamiento de tráfico cursado por algunas aplicaciones.	36
Tabla 3-11. Relación proporcional del tráfico cursado en la red.	36
Tabla 3-12. Atributos del conjunto de datos.	39
Tabla 3-13. Retardo de extremo a extremo.	42
Tabla 3-14. Retardo correspondiente al codificador.	43
Tabla 3-15. Valores de retardo a considerar.	44
Tabla 3-16. Análisis de los valores de Jitter promedio y máximo.	46
Tabla 3-17. Selección del algoritmo de agrupación.	48
Tabla 3-18. Proceso de análisis del agrupamiento.	50
Tabla 3-19. Relación de los parámetros de calidad con MOS.	51
Tabla 3-20. Variación del número de ejecuciones de SMOTE.	53
Tabla 4-1. Prueba de entrenamiento: Máquina de vector de soporte.	56
Tabla 4-2. Prueba de entrenamiento: Árbol de decisión.	56
Tabla 4-3. Prueba de entrenamiento: Red neuronal.	57
Tabla 4-4. Prueba de entrenamiento: Redes bayesianas.	57
Tabla 4-5. Matriz de confusión: Redes neuronales.	58
Tabla 4-6. Matriz de confusión: Árbol de decisión.	59
Tabla 4-7. Matriz de confusión: Redes bayesianas.	59
Tabla 4-8. Matriz de confusión: Máquinas de vector de soporte.	60
Tabla 4-9. Análisis de precisión.	61
Tabla 4-10. Promedio precisión.	62
Tabla 4-11. Diferencia del promedio de precisión.	62
Tabla 4-12. Ranking Test.	63
Tabla 4-13. Summary Test.	63
Tabla 4-14. Precisión y tiempo de respuesta de los algoritmos.	64
Tabla 4-15. Comparación de la precisión los dos conjuntos de datos	65
Tabla 5-1. Resumen políticas.	72
Tabla A-1. Prueba de entrenamiento: Máquina de vector de soporte.	89
Tabla A-2. Prueba de entrenamiento: Árbol de decisión.	89
Tabla A-3. Prueba de entrenamiento: Red neuronal.	89
Tabla A-4. Prueba de entrenamiento: Redes bayesianas.	90

LISTA DE ACRÓNIMOS

BER:	<i>Bit Error Rate</i> (Tasa de Bits Erróneos)
BN:	Bayesian Networks
CAC:	<i>Call Admission Control</i> (Control de Admisión de Llamadas)
CRT:	Comisión de Regulación de Telecomunicaciones
DSL:	<i>Digital Subscriber Line</i> (Línea Digital de Abonado)
DT:	Decision Tree
IEEE:	<i>Institute of Electrical and Electronics Engineers</i> (Instituto de Ingenieros Eléctricos y Electrónicos)
IP:	<i>Internet Protocol</i> (Protocolo de Internet)
ITU:	<i>International Telecommunications Union</i> (Unión Internacional de Telecomunicaciones)
MAC:	<i>Media Access Control</i> (Control de Acceso al Medio)
NN:	Neuronal Networks
PC:	<i>Personal Computer</i> (Computador Personal)
PSTN:	<i>Public Switched Telephone Network</i> (Red de Telefonía Pública Conmutada)
QoS:	<i>Quality of Service</i> (Calidad de Servicio)
RTPC:	Red telefónica pública conmutada
SLA:	<i>Service Level Agreement</i> (Acuerdo de Nivel de Servicio)
SVM:	Support Vector Machines
TIC:	Tecnologías de Información y Comunicación
VoIP:	<i>Voice over IP</i> (Voz sobre IP)
WAN:	<i>Wide Area Network</i> (Red de Área Amplia)
xDSL:	<i>Any Digital Subscriber Line</i> (Cualquier Línea Digital de Abonado)

1 Capítulo: Introducción

1.1 Contexto

Con el rápido crecimiento de las sociedades, los volúmenes de información a transportar cada vez son mayores y los tiempos de respuesta deben ser menores [1]. Por esta razón, surgen nuevos retos en la gestión de las redes de telecomunicaciones y en la prestación de servicios en tiempo real con Calidad de Servicio (QoS, Quality of Service). En los intentos por hacer frente a estas exigencias, las investigaciones se han enfocado en fusionar temas de inteligencia artificial (Aprendizaje de máquina) y minería de datos para detectar patrones de comportamiento que permitan automatizar procesos y brindar a los administradores herramientas en la gestión eficiente de las redes[2].

Por otra parte, los administradores de red toman decisiones con base a las capacidades de la red y Acuerdos de Nivel de Servicio (SLA, Service Level Agreement), teniendo en cuenta parámetros de calidad como retardo, rendimiento, tasas de error y disponibilidad. La especificación del servicio es generalmente estática, sin embargo, muchos clientes requieren servicios que se ajusten a determinados requerimientos de usuario y calidad de servicio [3] .

Teniendo en cuenta que en las redes IP es difícil garantizar calidad de servicio por factores como fallas, estado de congestión o adaptación a los cambios en los requisitos de la aplicación; se hace necesario identificar las condiciones anteriormente mencionadas y para la extracción de patrones que permitan generar políticas en la gestión de las mismas[4].

La gestión basada en políticas es una solución ampliamente utilizada para las redes de entidades públicas o privadas. Dichos sistemas son impulsados por las necesidades del negocio los cuales requieren soluciones de gestión auto-adaptables y que cambien de acuerdo al comportamiento del sistema administrado[3].

1.2 Motivación

El avance de las redes de telecomunicaciones ha permitido a las personas comunicarse de una manera más eficiente, superando las barreras de tiempo y distancia. La invención del teléfono y su rápida evolución, paralelo al desarrollo de las redes basadas en el protocolo IP, brindan hoy en día una solución económica para los usuarios del servicio de telefonía[5]; sin embargo, el reto es brindar un servicio que cumpla con los estándares de calidad recomendados por los organismos de regulación, con miras a la convergencia que propone las redes de próxima generación. Teniendo en cuenta las ventajas que prometen los servicios convergentes[6], como la telefonía IP, es importante enfocar los estudios a la corrección de las falencias que se presentan, al ser ésta una comunicación en tiempo real basada en conmutación de paquetes.

Por otra parte, se ha incursionado en el campo de la inteligencia artificial aplicada a las redes de telecomunicaciones, con el propósito de mejorar la prestación de servicios. Así, tomando como referencia la arquitectura de las redes de próxima generación se evidencia un largo trayecto en la aplicación de técnicas de aprendizaje automático para la detección de spam, fraudes, clasificación de tráfico, entre otros; mientras que por ejemplo, en el área de voz sobre IP aún se pueden realizar mejoras mediante esta rama de la inteligencia artificial [7][8][9] .

En este sentido, el servicio de telefonía IP ha logrado gran auge en los últimos años al ser una solución económica especialmente para las empresas; sin embargo, aún existen algunos usuarios que prefieren la red telefónica conmutada por su excelente calidad. La aplicación de técnicas de inteligencia artificial al servicio de voz sobre IP promete disminuir esta brecha y propiciar la supervisión y mejoramiento de la calidad. Este estudio pretende hacer uso de técnicas de aprendizaje de máquina para analizar el estado de la red y proponer un control de admisión de llamadas mediante la premisa de políticas de calidad.

1.3 Definición del problema

La Voz sobre IP (VoIP, Voice Over Internet Protocol), es una tecnología que permite a los usuarios realizar llamadas a través de internet, a diferencia de los servicios de voz prestados por la red telefónica pública conmutada (PSTN, Public Switched Telephone Network) o red tradicional; en esta tecnología la voz es enviada en forma de paquetes de datos y no a través de circuitos conmutados.

Para todas las aplicaciones que están basadas en el protocolo IP, el tráfico es uno de los parámetros críticos que debe ser analizado para una adecuada prestación del servicio; en el caso de la Telefonía IP es de vital importancia que dicho análisis

sea en tiempo real para compensar la calidad del servicio prestado en caso de presentarse saturación del enlace o pérdida de paquetes.

En mayor detalle, una de las políticas que se puede considerar en un sistema de telefonía IP es el Control de Admisión de Llamadas (CAC, Call Admission Control) que hace uso de un mecanismo de toma de decisiones sobre la degradación del servicio en función de los parámetros de calidad, bien sea aceptando o rechazando nuevas llamadas sin afectar las que ya están en curso[10]. En particular, el cumplimiento de este conjunto de políticas permite la ejecución de algunas funciones de la capa de control en las redes de nueva generación[11] y dada su importancia, se ha propuesto el uso de técnicas de aprendizaje automático para potencializar su rendimiento con el fin de soportar la adecuada toma de decisiones sobre la prestación oportuna del servicio de voz (en tiempo real y de manera confiable), con base en parámetros relevantes de calidad de servicio.

En los últimos años, se han desarrollado varios estudios con el fin de mejorar el rendimiento del CAC para garantizar la calidad de servicio (QoS, Quality of Service); sin embargo, no es clara la manera como se realiza este proceso en comunicaciones de voz sobre IP y la razón por la cual existe una tendencia al uso de Redes Bayesianas, haciéndose necesaria la realización de un estudio comparativo [7][9].

Con base en lo anterior, el presente trabajo parte de la siguiente pregunta de investigación:

¿Cómo realizar de manera eficiente el control de admisión de llamadas para lograr calidad de servicio en comunicaciones de voz sobre IP?

1.4 Objetivos

1.4.1 Objetivo General.

Proponer un mecanismo de control de admisión de llamadas a partir de la comparación de diferentes técnicas de aprendizaje automático.

1.4.2 Objetivos Específicos.

- Caracterizar el dominio de aplicación para determinar los parámetros de QoS que influyen en la admisión de llamadas de servicios de VoIP

- Preparar el conjunto de datos que describa los parámetros de QoS en la admisión de llamadas de VoIP.
- Seleccionar los modelos de predicción de los parámetros de QoS para la admisión de llamadas de VoIP.
- Definir las políticas para el control de admisión de llamadas que permitan alcanzar la QoS aceptada para el servicio de VoIP.

1.5 Contribuciones

Este proyecto genera contribuciones a nivel académico e investigativo, expuestos a continuación:

- Conjunto de datos que describan las características relevantes de las llamadas de voz sobre IP.
- Estudio comparativo de algoritmos de aprendizaje supervisado para determinar la calidad de las llamadas de Voz sobre IP.
- Políticas para el control de admisión de llamadas en un servicio de voz sobre IP basadas en la calidad del servicio y soportadas en algoritmos de aprendizaje supervisado.

2 Capítulo: Estado del arte

Este capítulo presenta una descripción de los conceptos y las brechas relevantes dentro de este trabajo de grado. Los conceptos explicados son: voz sobre IP, calidad de servicio, aprendizaje automático y control de admisión de llamadas, presentando un conjunto de trabajos que relacionan la aplicación de técnicas de aprendizaje automático en las redes y servicios de telecomunicaciones, finalmente se definen los aportes de este proyecto.

2.1 Contexto general

2.1.1 Voz sobre protocolo de internet – VoIP

VoIP “Voice Over Internet Protocol” es un estándar de la Unión Internacional de Telecomunicaciones (ITU, Internacional Telecommunications Union) que consiste en la emisión de voz en paquetes IP sobre redes de datos, como puede ser Internet, facilitando el uso de dichas redes para efectuar las llamadas telefónicas y así desarrollar una red convergente que se encargue de cursar todo tipo de información o de tráfico. VoIP es una tecnología y no un servicio que permite encapsular la voz en paquetes para poder ser transportados sobre redes de datos sin necesidad de disponer de la PSTN, la cual era utilizada para la transmisión de señales de voz. A diferencia de la red pública que utiliza conmutación de circuitos, la telefonía IP envía múltiples conversaciones a través del mismo canal (circuito virtual) codificadas en paquetes y en flujos independientes. Cuando se produce un silencio en una conversación, los paquetes de datos de otras conversaciones pueden ser transmitidos por la red, lo que implica un uso más eficiente de la misma. Las alternativas tecnológicas de VoIP se pueden dividir en dos grupos: tecnologías cerradas propietarias por ejemplo Skype o Cisco Skinny (SCCP), entre otros y sistemas abiertos como los estándares basados en SIP, H.323 o IAX.[12][13]

2.1.1.1 Protocolos

Existen varios protocolos que hacen posible el correcto funcionamiento de la tecnología VoIP, como se muestra en la Figura 2-1, y se pueden clasificar en [13][14]:

- Protocolos de señalización: tienen un mecanismo de conexión que abarca una serie de transacciones de señalización entre terminales que cargan dos flujos de audio para cada dirección de la conversación, estos protocolos son: H.323, SIP, MGCP, Megaco, IAX :
- Protocolos de transporte: trabajan en el cuarto nivel del modelo OSI, son los encargados de la transferencia de datos entre un emisor y un receptor, estos protocolos son: UDP y TCP:
- Protocolo de comunicación: El protocolo utilizado para la comunicación entre los dispositivos telefónicos es RTP (Real Time Protocol), este protocolo se encarga de las comunicaciones en tiempo real y opera sobre el protocolo de transporte UDP:

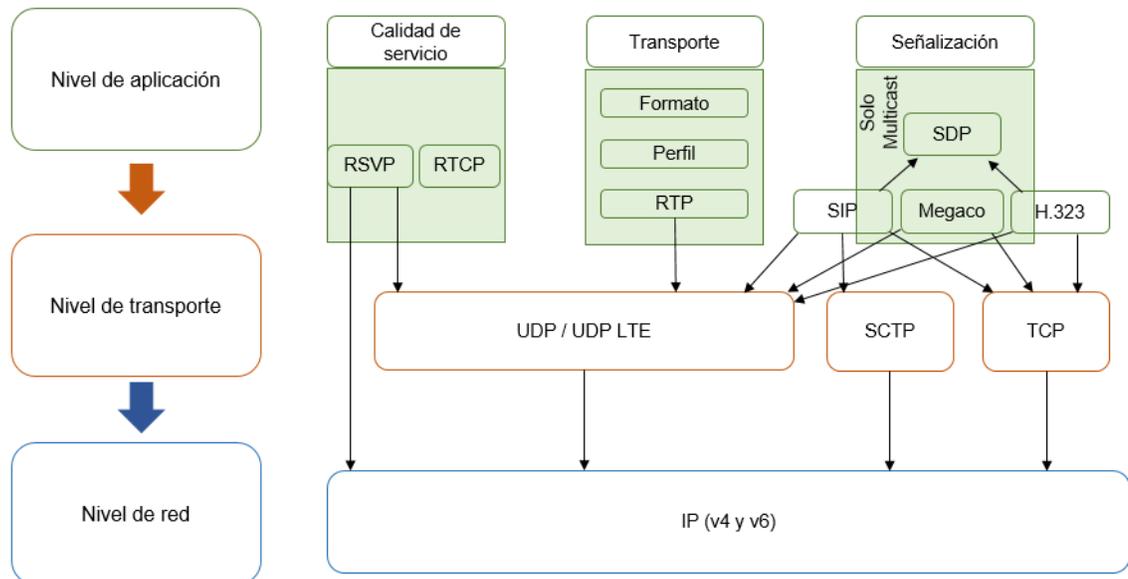


Figura 2-1. Protocolos IP.

2.1.1.2 Códecs

Como la voz se transmite por un canal de datos, es necesario transformar la señal análoga (voz) a digital. El codificador-decodificador (CÓDEC) convierte la señal análoga del teléfono en señales PCM (pulse code modulation), muestras que pasan por el algoritmo de compresión que comprime y fracciona la voz en paquetes. Al otro extremo del canal de comunicación se realiza el proceso inverso.

El uso de los códecs ayuda a reducir el número de bits por conversación de voz, traduciéndose en un mayor número de llamadas simultáneamente con un ancho de banda finito. La compresión tiene como objetivo eliminar la redundancia de los datos que son enviados. Usualmente entre más comprimida sea la señal de voz más

recursos usará el procesador de señal digital (DSP), por lo que estos códecs se clasifican por su complejidad.

A continuación, se mencionan algunos códecs:

- ITU G711 (o PCM): muestrea la señal de voz a una frecuencia de 8 000 muestras por segundo. Se encuentra en todas las aplicaciones, equipos y protocolos VoIP.
- ITU G729: Permite una compresión de voz que sólo requiere de 8 Kbps por llamada en vez de los 64 Kbps requeridos por el G.711, lo cual significa que se realizan ocho llamadas en el espacio de una que estuviera usando G.711.

Existen diversos estándares que explican los algoritmos y esquemas de codificación utilizados en cada uno de los códecs, unos más complejos que otros. En la siguiente tabla se presenta el resumen de los códecs más conocidos:[15]

Tabla 2-1. Principales códecs de VoIP.

Nombre	Estándar	Bit rate (kb/s)	Sampling rate (kHz)	Frame size (ms)	MOS (Mean Opinion Score)
G.711	ITU-T	64	8	Muestreada	4.1
G.723.1	ITU-T	5.6/6.3	8	30	3.8 – 3.9
G.726	ITU-T	16/24/32/40	8	Muestreada	3.85
G.729	ITU-T	8	8	10	3.92
GSM	ETSI	13	8	22.5	

2.1.2 Calidad de servicio – QoS

La Calidad de Servicio según la IETF en su RFC 2386 se define como el “Conjunto de requisitos del servicio que debe cumplir la red en el transporte de un flujo”, mientras que para la ITU se define como “la totalidad de las características de un servicio de telecomunicaciones que determinan su capacidad para satisfacer las

necesidades explícitas e implícitas del usuario del servicio”, cuando las características se convierten en parámetros cuantitativos proporcionan información para medir niveles de QoS en la prestación de un servicio.

2.1.2.1 Parámetros de desempeño

Los parámetros que miden la QoS en un sistema de Telefonía IP son retardo, pérdida de paquetes y Jitter, su análisis permite diagnosticar el estado de la red.[16]

- Retardo: Es el tiempo que tarda un paquete de información en ser recibido por el host (terminal) final o receptor desde que la trama de datos comenzó a ser transmitida por el host inicial o emisor.
- Pérdida de paquetes: Es el porcentaje de paquetes transmitidos que se descartan en la red, debido a una alta tasa de error en alguno de los medios de enlace o por sobrepasarse la capacidad de un buffer de una interfaz en momentos de congestión.
- Jitter: Son las variaciones de retardo que se presentan entre paquetes. Por ejemplo, un paquete llega con un retardo de 110 ms al destino y el segundo paquete, con un retardo de 130 ms; entonces el jitter es de 20 ms entre paquetes.

2.1.2.2 Clases de servicio

La recomendación Y.1541 (ITU, 2011b, 9) define un número de clases de QoS para los diferentes servicios [17]

- Clase 0: Está definida para aplicaciones sensibles al retardo y de alta iteración como VoIP y VTC (Video Teleconference). Emplea mecanismos de cola separada por prioridad, preparación de tráfico y uso de técnicas de enrutamiento y distancia limitadas (ITU,2011b, 12).
- Clase 1: Al igual que la clase 0 está definida para aplicaciones de tiempo, sensibles al retardo y de alta iteración como VoIP y VTC, Emplea mecanismos de colas separados con servicio preferencial, preparación de tráfico. A diferencia de la anterior usa técnicas de enrutamiento y distancia menos limitadas.
- Clase 2: Definida para aplicaciones de datos transaccionales y aplicaciones altamente interactivas.
- Clase 3: Definida para aplicaciones de datos transaccionales e interactivas.
- Clase 4: Aplicaciones que soporten pérdidas bajas como transacciones cortas.
- Clase 5: Definida para aplicaciones tradicionales de redes IP.

2.1.3 Aprendizaje automático – ML

El *aprendizaje automático* es una rama de la inteligencia artificial (AI) que tiene como objetivo el desarrollo de técnicas que proporcionen a las computadoras la capacidad de aprender sin ser programadas de forma explícita, es decir, es un proceso de inducción del conocimiento para que mediante algoritmos y sin la intervención del ser humano la máquina pueda hacer un análisis de los datos suministrados en su entrenamiento y aprender de los mismos. Aprender en este contexto quiere decir identificar patrones complejos en millones de datos.

Existen varios tipos de aprendizaje automático, entre los cuales se tiene el aprendizaje supervisado, no supervisado, semi-supervisado, por refuerzo, multi-tarea y transducción.

2.1.3.1 Aprendizaje supervisado

Uno de los más utilizados es el aprendizaje supervisado en el cual los algoritmos realizan predicciones basadas en un conjunto de ejemplos, generando una función que relaciona las entradas y las salidas del sistema. Algunos de los algoritmos son[18]:

- *Árbol de decisión*: Su principal objetivo es exponer de forma estructural la información contenida en los datos. Clasifica los valores que los atributos (llamados casos) tomando como modelo un árbol, donde cada nodo representa una instancia de un atributo, y cada rama descendente desde el nodo corresponde a uno de los posibles valores que puede tomar el atributo.
- *Red bayesiana*: modelar un conjunto de variables y las relaciones de dependencia entre ellos, haciendo uso del teorema de Bayes. A través de este modelo, la probabilidad de variables desconocidas se puede estimar, sobre la base de variables conocidas. Estos modelos pueden tener diversas aplicaciones: clasificación, predicción, diagnóstico, etc.
- *Red Neuronal*: emulan la estructura computacional de los sistemas nerviosos de los animales para resolver tareas que la computación algorítmica tradicional no ha sido capaz de resolver satisfactoriamente. Entre las principales ventajas de las redes neuronales están: aprendizaje adaptativo, la capacidad de auto-organización, la conmutación por error, y la integración de diversas tecnologías.

- *K-vecinos más cercanos*: clasifica un nuevo dato de entrada, de acuerdo con los datos de entrenamiento k más cercanos a los que le rodean, donde k es un número entero definido por el usuario.
- *Máquinas de vectores soporte*: es un método propuesto para resolver los problemas de clasificación y regresión. El funcionamiento básico comienza con un conjunto de puntos, que a su vez contiene dos subconjuntos de puntos, en el que cada uno pertenece a una de las dos clases posibles. Basado en esto, la máquina de vectores de soporte busca la mayor distancia que separa las clases por medio de un hiperplano, con el fin de construir un modelo que es capaz de predecir si un nuevo punto (de clase desconocida) pertenece a una clase o la otra.

2.1.4 Control de admisión de llamadas - CAC

La ITU (International Telecommunication Union) propone una arquitectura para las redes de próxima generación definida mediante dos estratos: transporte y servicios; ambos estratos interactúan a través de las RACF, encargadas de soportar el control de la QoS a través del CAC.[10][19]

El control de admisión de llamadas (CAC) actúa como árbitro en la gestión de recursos de transporte relacionados con la QoS y se define como un conjunto de acciones/políticas que en función de criterios de calidad de funcionamiento o priorización del tráfico se llevan a cabo en la fase de establecimiento de una llamada/sesión para aceptar o rechazar un servicio y así evitar la prestación del mismo con baja calidad [20]; éstas políticas son implementadas por el enrutador de frontera para limitar la entrada de tráfico en los bordes de la red en tiempo real.

2.2 Antecedentes

Se llevó a cabo un mapeo sistemático de estudios para proporcionar una visión general del área de investigación, determinar la cantidad y tipo de trabajos, además de los resultados disponibles.

El tema de interés seleccionado fue aprendizaje automático aplicado al dominio de las redes de telecomunicaciones. Para realizar una búsqueda confiable se seleccionaron varias herramientas y bases de datos de investigación científica, como Ebsco, Science Direct, Google Académico, Microsoft Academic Research, sin embargo, IEEE Xplore proporcionó la mayor cantidad de artículos relacionados con el tema de investigación durante los últimos 10 años.

Después de seleccionar 50 artículos, estos fueron organizados cronológicamente con el propósito de realizar una revisión detenida del resumen y las palabras claves, identificando así los núcleos temáticos de búsqueda. Como se presenta en la Figura 2-2, durante el periodo 2008 - 2012 la cantidad de publicaciones aumentó, en los siguientes años se mantuvo constante hasta el 2015, exceptuando el año 2014 cuando se registra una leve caída. Este comportamiento indica que durante los últimos 10 años ha crecido el interés en esta área del conocimiento.

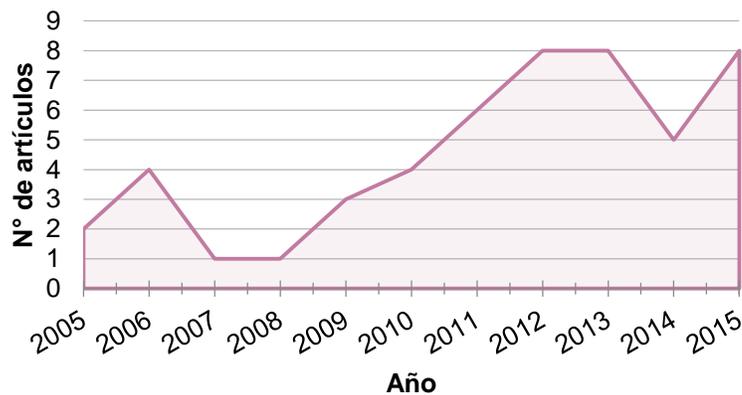


Figura 2-2. Trabajos relacionados por año.

La cadena de búsqueda inicial dio una visión general de las investigaciones relacionadas en el ámbito científico, por lo cual se incluyen como unidades documentales los artículos y se excluyen los libros y blogs. Se hace una revisión detenida del resumen de los artículos y las palabras claves, con el propósito de seleccionar los núcleos temáticos de búsqueda. En aprendizaje automático se detectan los algoritmos aplicados en telecomunicaciones, tales como redes bayesianas, redes neuronales, árboles de decisión, máquinas de vector soporte, entre otros, y en Networking las Redes de próxima generación y QoS; por lo tanto, se decide clasificar las unidades documentales con base a la arquitectura de las NGN (Next Generation Networks), discriminando los artículos en cuatro grupos: estrato de transporte, estrato de servicios, acceso y control (RACF).

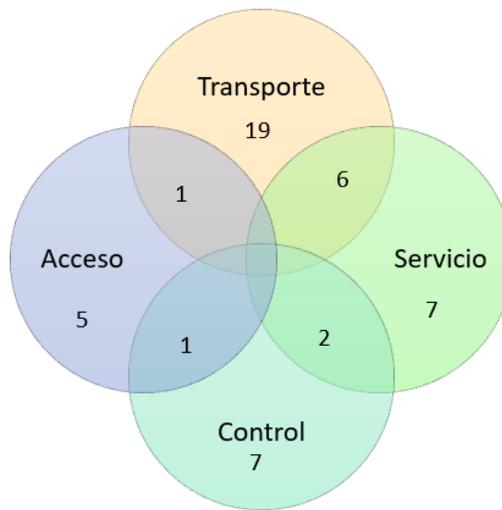


Figura 2-3. Distribución de los trabajos relacionados por capas NGN.

La Figura 2-3 resume la distribución de los trabajos relacionados con respecto a las capas de la NGN, encontrando la mayor cantidad de trabajos en el estrato de transporte con 26 artículos y en el estrato de servicio con 15, mientras que en la capa de control se tienen 10 artículos y en la capa de acceso 7. En las gráficas presentadas a continuación, se exponen los algoritmos detectados en cada grupo y la cantidad de artículos que hacen referencia a ellos:

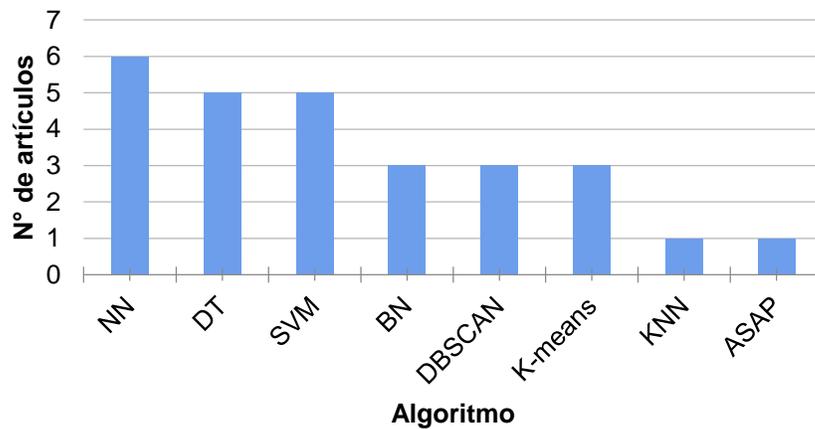


Figura 2-4. Número de artículos por algoritmo usados en la capa de transporte.

La Figura 2-4 corresponde a los algoritmos aplicados en la capa de transporte, el más implementado es Redes Neuronales con 6 artículos relacionados, seguido por arboles de decisión y Maquinas de vector de Soporte con 5 artículos cada uno.

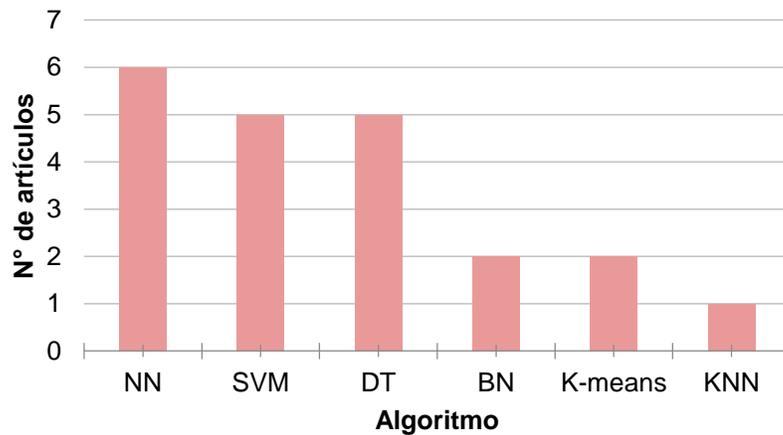


Figura 2-5. Número de artículos por algoritmo usados en la capa de capa de servicio.

La Figura 2-5 corresponde a los algoritmos aplicados en el estrato de Servicio, al igual que en el estrato de transporte, el algoritmo más implementado es Redes Neuronales con 6 artículos, seguidas por Maquinas de vector de Soporte y árboles de decisión con 5.

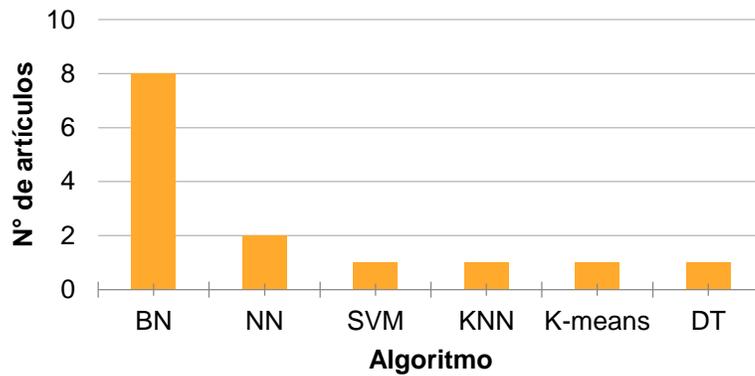


Figura 2-6. Número de artículos por algoritmo usados en la capa de control.

La Figura 2-6 corresponde a los algoritmos aplicados en la capa de control, es evidente la tendencia por el uso de las redes bayesianas con 8 trabajos, seguidas de las redes neuronales con 2.

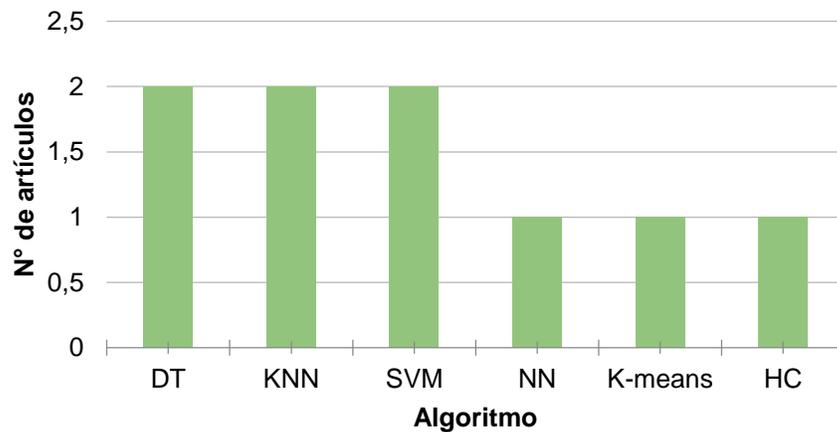


Figura 2-7. Número de artículos por algoritmo usados en la capa de acceso.

La Figura 2-7 corresponde a los algoritmos aplicados en la capa de acceso. Se encuentra 2 trabajos relacionados para cada uno de los siguientes algoritmos: arboles de decisión, KNN y Maquinas de vector de Soporte.

A continuación, en la Tabla 2-2 se referencian los artículos correspondientes a cada grupo de clasificación con una descripción general de su enfoque.

Tabla 2-2. Clasificación de los trabajos relacionados.

CLASIFICACION	TRABAJOS RELACIONADOS	DESCRIPCIÓN
CAPA DE ACCESO	[32],[43],[48],[49],[58],[59],[61]	Teniendo en cuenta la multiplicidad de tecnologías a nivel de acceso que requieren las redes NGN para brindar un alto ancho de banda y soportar servicios convergentes, se han desarrollado estudios enfocados en el mejoramiento de los recursos físicos y solución de problemas como la interferencia en redes a través del rastreo de múltiples trazas de tráfico para describir la interacción entre nodos de la red. Se generan investigaciones variando la tecnología de acceso y el tipo de red (LAN, MAN, WAN).
CAPA DE TRANSPORTE	[21],[23],[24],[25],[31],[34],[35],[36],[37],[38],[39],[40],[42],[43],[44],[45],[46],[47],[48],[50],[53],[54],[55],[56],[57],[62]	Los trabajos analizados en esta capa se centran en la clasificación del tráfico con diferentes enfoques, como por ejemplo el diagnóstico de la red, comportamientos anómalos, entre otros.
CAPA DE CONTROL	[21],[26],[27],[28],[33],[41],[57],[64],[65],[66]	La capa de control es la encargada de la gestión y correcto funcionamiento de las demás capas; entre sus funciones está el control de servicio de llamadas y la gestión de los perfiles de usuario. Los trabajos relacionados están enfocados en garantizar los requerimientos de las NGNs implementando políticas como el CAC.
CAPA DE SERVICIO	[21],[22],[23],[29],[30],[40],[44],[37],[47],[43],[46],[51],[52],[60],[63],[66]	Gran parte de los trabajos relacionados en esta capa se centran en encontrar patrones que determinen comportamientos futuros de los usuarios e información importante para empresas de telecomunicaciones, como por ejemplo la predicción de la deserción de clientes o la cantidad de tráfico que se requerirá en una aplicación.

La menor cantidad de trabajos fueron encontrados en las capas de acceso y control. De acuerdo a la documentación consultada, la aplicación de aprendizaje automático en la capa de acceso es dependiente de la tecnología, y los resultados expuestos es posible aplicarlos a entornos con características muy particulares. En contraste,

para la capa de control se proponen soluciones que puedan ser usadas de manera independiente a la tecnología de acceso y a su vez aplicadas a un campo más amplio. Se decide profundizar la investigación en la capa de control, encontrando que es un área en donde es posible generar un aporte significativo. Se toma como referencia los siguientes trabajos:

1. *"A Novel Application of Bayesian Reasoning for Proactive Network Management"* [67]: Este trabajo busca capturar de forma adaptativa el comportamiento estocástico del estado de la red, con el objetivo de automatizar las funciones de supervisión del rendimiento de la misma. Se propone aplicar BBN (Bayesian network Belief) utilizando protocolos de gestión de red SNMP (Network Management Protocol). Los autores plantean un Modulo denominado BARD (BAYesian Reasoner and Decision-maker) para darle autonomía a la red en la toma de decisiones basados en parámetros de calidad de servicio.
2. *"Machine Learning based Call Admission Control Approaches: A Comparative Study"* [28]: Este trabajo propone implementar técnicas de aprendizaje automático para mejorar el rendimiento del CAC, encargado de tomar las decisiones de admisión/negación de los servicios. Los autores realizan las pruebas con redes bayesianas (BN) y redes neuronales (NN), midiendo su precisión en la predicción de retardo y pérdida de paquetes, así también como su velocidad de aprendizaje; concluyen que el tamaño del conjunto de datos de entrenamiento para el modelo BN es menor que para el modelo NN; además de que para mejorar el CAC, los algoritmos deberían basarse en la pérdida de paquetes en lugar de los retardos.
3. *"A Novel Distributed Call Admisión Control Solution based on Machine Learning Approach"*[68]: Este trabajo presenta una comparación del rendimiento de redes bayesianas en un entorno distribuido y centralizado, para la toma de decisiones basadas en CAC mediante la utilización de parámetros de calidad de servicio, en este caso la precisión en la predicción de los retardos. Al comparar los dos enfoques encontraron que la precisión máxima del retardo en escenarios distribuidos es de 79.3%, mientras que en escenarios centralizados es de 90,5%, aunque requiere aproximadamente un 60% más de memoria.
4. *"Performance analysis of Bayesian Networks-based distributed Call Admission Control for NGN"*[65]: Este trabajo presenta una comparación del rendimiento de redes bayesianas en un entorno distribuido y centralizado evaluando diferentes métricas: Precisión en la predicción, tiempo de aprendizaje, toma de decisiones y probabilidad de bloqueo. Al comparar los escenarios, obtienen que la precisión de la predicción es mejor para un escenario centralizado, pero gasta un 75% más de tiempo de aprendizaje. Por otra parte, la toma de decisiones tiene un comportamiento similar en

cuanto al tiempo de respuesta en ambos entornos y la probabilidad de bloqueo arroja mejores resultados en el escenario distribuido ya que las solicitudes de llamadas se procesan más rápido y al disminuir el tiempo de respuesta se bloquea una menor cantidad de llamadas.

5. *"Predicting the Quality Level of a VoIP Communication through Intelligent Learning Techniques"* [64]: Este trabajo presenta un método para determinar la calidad de una comunicación VoIP, utilizando los árboles de decisión (J.48), redes neuronales (Perceptrón multicapa) y Redes Bayesianas (Naives); los cuales a partir de datos históricos de parámetros de la red son capaces de aprender y determinar la calidad de servicio de la misma. Los autores emplean un entorno de red emulada y después de realizar alrededor de 300 pruebas, determinan que el valor más elevado de fiabilidad en la estimación de la calidad de las comunicaciones VoIP es de 0,98 con el uso del algoritmo de árboles de decisión.

La Tabla 2-3 resume las brechas encontradas en los trabajos anteriores:

Tabla 2-3. Brechas

ARTÍCULO	BRECHA
"A Novel Application of Bayesian Reasoning for Proactive Network Management" [67].	No se especifica porqué se hace uso de redes bayesianas y no de otro algoritmo; además de omitir el criterio de selección del retardo como parámetro de calidad de servicio utilizado en el análisis de rendimiento del algoritmo.
"Machine Learning based Call Admission Control Approaches: A Comparative Study" [28].	Los autores realizan un estudio comparativo entre Redes Bayesianas y Neuronales, variando el parámetro de calidad de servicio (Retardo-Pérdida de paquetes). El estudio considera que estos algoritmos son los mejores, pero no argumenta el porqué de la afirmación.
"A Novel Distributed Call Admission Control Solution based on Machine Learning Approach" [68].	Se desarrolla un estudio comparativo entre entornos centralizados y distribuidos variando el algoritmo de aprendizaje automático (redes bayesianas) y utilizando como parámetro de QoS el retardo. No se puede concluir cuál escenario tiene mejor rendimiento ya que el resultado depende del dominio de aplicación.
"Performance analysis of Bayesian Networks-based distributed Call Admission Control for NGN" [65].	Los modelos de CAC son entrenados en entornos distribuidos y centralizados (Offline), aplicando Redes bayesianas y evaluando cinco métricas de desempeño en una red simulada para tomar decisiones de CAC en tiempo real (Online), sin embargo, se omite el criterio de selección del parámetro de calidad de servicio (retardo) y del algoritmo utilizado.

"Predicting the Quality Level of a VoIP Communication through Intelligent Learning Techniques" [64].	Este trabajo realiza una evaluación del nivel de calidad de servicio sobre VoIP, centrándose en el servicio de voz y no de video.
--	---

2.5 APORTES DEL TRABAJO DE GRADO

Este proyecto genera aportes a nivel académico e investigativo, expuestos a continuación:

- Conjunto de datos que describan las características relevantes de las llamadas de voz sobre IP.
- Estudio comparativo de algoritmos de aprendizaje supervisado para determinar la calidad de las llamadas de Voz sobre IP.
- Políticas para el control de admisión de llamadas en un servicio de voz sobre IP basadas en la calidad del servicio y soportadas en algoritmos de aprendizaje supervisado.

3 Capítulo: Construcción del conjunto de datos

Este capítulo presenta una descripción detallada del procedimiento realizado para la construcción del conjunto de datos, utilizando las primeras fases de la metodología CRISP-DM (comprensión del negocio, comprensión y preparación de los datos) y las consideraciones tenidas en cuenta en la definición del escenario de pruebas para este trabajo de grado, centrándose en un estudio de caso específico de una red de computadores. Además, se presenta la caracterización y selección de las herramientas para la generación de los datos, siguiendo un conjunto de criterios específicos. Finalmente se expone el uso de técnicas de agrupamiento para el análisis de patrones dentro de los grupos de llamadas generados y su relación con niveles de Calidad de Servicio como parte fundamental en el planteamiento de políticas para la admisión de llamadas.

3.1 Generación de datos

Las redes basadas en el protocolo IP ofrecen un único nivel de servicio: Best Effort, es decir, no se lleva a cabo ningún tipo de reserva de recursos, retraso máximo sufrido por los paquetes, ni se garantiza que los paquetes lleguen correctamente a su destino.

La Voz sobre IP hace parte de los servicios que prestan las redes de próxima generación. La Figura 3-1 ilustra los protocolos por capa, de donde se espera extraer la información para la construcción del conjunto los datos:



Figura 3-1. Protocolos importantes en la construcción del conjunto de datos.

Por otra parte, SIP es el protocolo encargado de la señalización en Voz sobre IP. Es el más usado gracias a su simplicidad, característica que limita la calidad de servicio a diferencia de otros protocolos como H.225/H.245 que lo hacen, pero al ser tan robustos no resulta factible su utilización.

Con ayuda de un conjunto de datos construido a partir de la información de llamadas de VoIP, se analizan patrones de comportamiento repetitivo para prever las condiciones de llamadas futuras y generar políticas de prestación de servicios.

Para la extracción de los datos se propone generar un gran número de llamadas SIP utilizando el protocolo UDP, afectado por tráfico externo IP y monitoreado con un analizador de tráfico en intervalos de tiempo definidos.

3.1.1 Descripción y herramientas (Asterisk-DITG-Wireshark-Sipp)

Existen cinco criterios de evaluación aplicados en la selección de software para sistemas de telecomunicaciones: funcionalidad, código abierto, comunidad de desarrolladores, compatibilidad con Linux y documentación. A continuación se describen los criterios importantes en la selección de la central de telefonía IP, el generador y el analizador de tráfico, para el desarrollo del escenario de pruebas[69][70].

3.1.1.1 Criterios de Selección de Software

A continuación, se describen los seis criterios de evaluación aplicados en la selección de software para el desarrollo del escenario de pruebas[69][70].

- **Funcionalidad:** Permite modelar el proceso de simulación. Criterio importante en este trabajo para evitar sobredimensionar el uso de una herramienta o desperdiciar recursos en la implementación.
- **Compatibilidad con Linux:** El sistema operativo Linux ofrece altas prestaciones en equipos con recursos limitados razón por la cual es importante que todo sistema prestador de servicios de telecomunicaciones pueda desplegarse sobre el mismo.
- **Comunidad de desarrolladores:** Este criterio se refiere al grupo de desarrolladores y personas o entidades que hacen uso de la herramienta.

Una comunidad de desarrolladores está calificada de acuerdo a la cantidad de información de experiencias y resultados obtenidos y compartido por todos los desarrolladores. Esta característica es importante en el presente trabajo ya que aporta a la comprensión del funcionamiento y características relevantes de las herramientas además de tener acceso a las experiencias y trabajos relacionados con la comunidad que las desarrolla.

- Documentación: Información ofrecida por el proveedor de la herramienta. Este criterio es fundamental puesto que permite la utilización de forma eficiente de las herramientas.

3.1.1.2 Herramientas preseleccionadas para el Servicio de VoIP

- Asterisk[71]: Es una plataforma de telefonía de código abierto que puede convertir un computador de propósito general en un servidor de comunicaciones VoIP. Es utilizado por empresas de todos los tamaños para mejorar su comunicación, incluyendo a Google, Yahoo, IBM.

Características de Asterisk

- Asterisk es un software gratuito, y se dispone del código fuente para lo que se desee.
 - Cualquier sistema compatible con Linux puede utilizarse con Asterisk
 - Se puede utilizar cualquier tipo de terminales que contengan señalización SIP, IAX o H.323, que son los tres protocolos más usados en la actualidad.
 - Pertenece a Digium lo que garantiza el funcionamiento de Asterisk y ofrece soporte técnico para sus versiones.
 - Asterisk es un sistema de comunicación seguro, debido a que su código es visible, cualquier detección de fallo de seguridad, es rápidamente publicado.
- Open Core IMS[72]: Open Source IMS Core es un proyecto de código abierto para realizar bancos de pruebas en el núcleo de la red IMS. Tiene como objetivo crear una comunidad de desarrolladores para los elementos centrales de redes de próxima generación (NGN) y las partes interesadas de IMS. La idea para los usuarios de este software es permitir el desarrollo de servicios IMS y probar conceptos alrededor del núcleo IMS que se basan en un software altamente configurable y extensible

- **Elastix:** Es un software de servidor de comunicaciones unificadas que reúne PBX IP, correo electrónico, mensajería instantánea, fax y funciones colaborativas. Cuenta con una interfaz Web e incluye capacidades como un software de centro de llamadas con marcación predictiva.

Los criterios para la selección de la central de telefonía IP son:

- **Funcionalidad:** Permite modelar el proceso de simulación de llamadas de voz sobre IP. Es el criterio más importante porque la central debe dar soporte a llamadas simultáneas de VoIP. Es decir, para este caso no es necesario que posea interfaz gráfica o tenga una alta usabilidad, sino que la central logre atender un gran número de llamadas simultáneas que tengan variaciones en sus características de calidad.
- **Compatibilidad con Linux:** El sistema operativo Linux ofrece altas prestaciones en equipos con recursos limitados. En nuestro caso, el computador a utilizar tiene un procesador Intel Core i7 3,4 GHz x 8 y 12 Gb de memoria RAM, como se presenta en la Tabla 3-5, características mínimas en comparación a los equipos utilizados en los grandes sistemas de telecomunicaciones. Dicho equipo estará dedicado a funcionar como central de VoIP, para soportar mayor cantidad de llamadas simultaneas y estudiar el comportamiento de las mismas. Por esta razón se decide que la herramienta más apropiada debe ser compatible con este sistema operativo.
- **Documentación:** Permite contar con la información suficiente por parte del desarrollador de la herramienta, para entender el funcionamiento de la misma, característica importante para comprender el dominio de aplicación en el cual se desarrolla el presente trabajo de grado.

En la Tabla 3-1 se ilustran los resultados obtenidos en la evaluación realizada para seleccionar las herramientas necesarias para el desarrollo e implementación de la Arquitectura de experimentación, donde se asignan valores en un intervalo de 0 a 5, siendo 0 la puntuación más baja y 5 la mejor.

Tabla 3-1. Comparación de centrales de VoIP.

Criterio	Asterisk	Open Core IMS	Elastix
Funcionalidad (40%)	5	5	5
Compatibilidad Linux (30%)	5	5	5
Documentación (30%)	5	2	4

Resultado	5	4.1	4.7
-----------	---	-----	-----

Teniendo en cuenta los resultados obtenidos se elige el servidor de VoIP Asterisk, el cual tuvo un puntaje final de 5 por cumplir con la función requerida para este trabajo de grado especificadas anteriormente y contar con la documentación más completa.

3.1.1.3 Generadores de tráfico IP

- DITG: Es una plataforma capaz de producir tráfico IPv4 e IPv6 con precisión mediante la replicación de la carga de trabajo de las aplicaciones actuales de Internet. Al mismo tiempo D-ITG es una herramienta de medición de red capaz de medir las métricas de rendimiento más comunes (por ejemplo, el rendimiento, retardo, Jitter, pérdida de paquetes) a nivel de paquete. D-ITG puede generar tráfico siguiendo modelos estocásticos para el tamaño de los paquetes (PS) y el tiempo de salida entre (IDT) que imitan el comportamiento de protocolo de nivel de aplicación. Al especificar las distribuciones de variables aleatorias IDT y PS, es posible elegir diferentes procesos de renovación para la generación de paquetes: mediante el uso de la caracterización y modelización de los resultados de la literatura, la D-ITG es capaz de replicarse propiedades estadísticas de tráfico de aplicaciones diferentes conocidos (por ejemplo, Telnet, VoIP - G.711, G.723, G.729, detección de actividad de voz, RTP comprimido - DNS, juegos en red).
- JTG: Es un generador de tráfico IP gestionado por línea de comandos, desarrollado por la Universidad de Helsinki, permite generar tráfico paramétrico y reproducir tráfico a partir de archivos con intervalos de tiempo y tamaños de paquetes a enviar en cada intervalo de tiempo. Por otro lado, provee un receptor para recoger el tráfico, a partir del cual se pueden calcular estadísticas.
- Ostinato Network Traffic Generator [73]: Es un generador de tráfico útil tanto para las pruebas de carga de la red y pruebas funcionales. Posee una Interfaz Gráfica para su manejo y permite crear y configurar múltiples flujos

Características de Ostinato

Soporte para los protocolos estándar más comunes

- ARP, IPv4, IPv6, IP-en-IP alias IP de túnel (6over4, 4over6, 4over4, 6over6)
- TCP, UDP, ICMPv4, ICMPv6, IGMP, MLD

- Cualquier protocolo basado en texto (HTTP, SIP, RTSP, NNTP etc.
- El tráfico de red de captura (*necesita Wireshark para ver los paquetes capturados*)
- Cruz-Plataforma - se ejecuta en Windows, Linux, BSD y Mac OS X
- FLOSS - gratuito, libre, software de código abierto

Los criterios para seleccionar el generador de tráfico externo son:

- **Funcionalidad:** Para efectos de este trabajo, el generador de tráfico externo debe simular flujos de aplicaciones IP como correo electrónico, buscador, video, entre otros, sin diferenciación de los servicios, permitiendo configurar parámetros que varíen la cantidad de tráfico en tres niveles: Alto, Medio y bajo. La herramienta debe permitir modificar la tasa de paquetes enviados por segundo durante intervalos de tiempo determinados.
- **Compatibilidad con Linux:** El sistema operativo Linux ofrece altas prestaciones en equipos con recursos limitados. En nuestro caso, el computador a utilizar tiene un procesador Intel Pentium 2,8 GHz x 2 y 4 Gb de memoria RAM, como se presenta en la Tabla 3-5, características mínimas en comparación a los equipos utilizados en los grandes sistemas de telecomunicaciones. Dicho equipo estará dedicado a funcionar como cliente, generando volúmenes de tráfico IP alto, medio y bajo.
- **Documentación:** Brinda información suficiente por parte del desarrollador de la herramienta para comprender el funcionamiento del generador y enviar diferentes volúmenes de tráfico. Este criterio es importante para entender los parámetros involucrados en la generación de tráfico IP externo como la tasa de bits por segundo, la longitud de los paquetes y los intervalos de tiempo de envío y así ser modificados para simular tráfico alto, medio y bajo en nuestro entorno de prueba.

En la Tabla 3-2 se ilustran los resultados obtenidos en la evaluación realizada para selección del generador de tráfico IP en el entorno de pruebas, donde se asignan valores en un intervalo de 0 a 5, siendo 0 la puntuación más baja y 5 la mejor.

Tabla 3-2. Comparación de generadores de tráfico.

Criterio	DITG	JTG	Ostinato
Funcionalidad (40%)	5	5	5
Compatibilidad Linux (30%)	5	5	5

Documentación (30%)	4	3	3
Resultado	4.7	4.4	4.4

Teniendo en cuenta los resultados obtenidos se selecciona como herramienta de generación de tráfico IP el software DITG, el cual tuvo un puntaje final de 4.7 por cumplir con las funcionalidades requeridas para este trabajo de grado especificadas anteriormente y contar con la mejor documentación.

3.1.1.4 Generadores de llamadas de VoIP

- Sipp[74]: Es la principal herramienta empleada, capaz de realizar múltiples llamadas de forma simultánea empleando dicho protocolo. o Es una aplicación Open Source, de análisis de rendimiento del protocolo SIP o Sipp también puede enviar tráfico RTP (audio/vídeo) a través del reenvío de tráfico RTP capturado en un archivo PCAP. o Sipp muestra en pantalla los resultados estadísticos de las pruebas que se estén ejecutando (ratio de llamadas por segundo, retraso de llegada de paquetes y estadísticas sobre cada uno de los mensajes del protocolo SIP).
- DITG: Como se mencionó en la sección 3.1.1.2, esta herramienta permite generar flujos IP de diferentes servicios entre ellos voz sobre IP.
- Zoiper: es un software utilizado para realizar llamadas a otros softphones o a otros teléfonos convencionales usando un VoIP (Voz sobre IP) o ToIP (Telefonía sobre IP). Es compatible con Linux, Windows y Mac.

Los criterios para seleccionar el generador de llamadas son:

- Funcionalidad: El generador de llamadas de VoIP debe permitir simular la estructura de una sesión/llamada adaptándose al comportamiento de condiciones cercanas a la realidad como la duración de la llamada (ref comisión) y el número de intentos de llamadas por segundo que puede realizar en promedio un cliente.
- Compatibilidad con Linux: Para el escenario de prueba propuesto es necesario generar un alto número de llamadas por intervalos de tiempo, y muchas de ellas realizándose simultáneamente, lo que hace necesario un alto consumo computacional. Teniendo en cuenta el sistema operativo Linux ofrece altas prestaciones al no consumir tantos recursos en funcionalidades como la interfaz gráfica, se hace importante que el generador de llamadas a utilizar sea compatible con este sistema operativo para alcanzar un número alto de llamadas.

- Documentación: Este criterio es importante para entender el funcionamiento de los parámetros involucrados en la generación de llamadas de VoIP como el número de la extensión, la duración de la llamada, número de intentos por segundo y así obtener un conjunto de llamadas con características diferentes en el conjunto de datos que se desea construir a partir de la información obtenida.

En la Tabla 3-3 se ilustran los resultados obtenidos en la evaluación realizada para selección del generador de tráfico IP en el entorno de pruebas, donde se asignan valores en un intervalo de 0 a 5, siendo 0 la puntuación más baja y 5 la mejor.

Tabla 3-3. Comparación de generadores de llamadas.

Criterio	Sipp	DITG	Zoiper
Funcionalidad (40%)	5	3	2
Compatibilidad Linux (30%)	5	5	5
Documentación (30%)	4	4	4
Resultado	4.7	3.9	3.5

Teniendo en cuenta los resultados obtenidos se selecciona como herramienta de generación de llamadas de VoIP el software Sipp. A pesar de que en los criterios de compatibilidad con Linux y documentación obtienen la misma calificación, en la funcionalidad se le asigna un puntaje de 5 porque permite configurar parámetros específicos de la llamada y generar llamadas simultáneas, a diferencia de las otras herramientas.

3.1.1.5 Analizadores de Tráfico

- Wireshark [75]: Es un analizador de protocolos código abierto diseñado por Gerald Combs y que actualmente está disponible para plataformas Windows y Unix. Conocido originalmente como Ethereal, su principal objetivo es el análisis de tráfico además de ser una excelente aplicación didáctica para el estudio de las comunicaciones y para la resolución de problemas de red. Wireshark implementa una amplia gama de filtros que facilitan la definición de criterios de búsqueda para los más de 1100 protocolos soportados actualmente (versión 1.4.3); y todo ello por medio de una interfaz sencilla e

intuitiva que permite desglosar por capas cada uno de los paquetes capturados. Wireshark “entiende” la estructura de los protocolos y permite visualizar los campos de cada una de las cabeceras y capas que componen los paquetes monitorizados, proporcionando un gran abanico de posibilidades al administrador de redes a la hora de abordar ciertas tareas en el análisis de tráfico.

Características:

Licencia: Open Source.

Sistemas operativos soportados: Linux, Mac OSX y Windows.

- **NTOPNG[76]**Es una herramienta que permite monitorizar en tiempo real una red. Es útil para controlar los usuarios y aplicaciones que están consumiendo recursos de red en un instante concreto y para ayudarnos a detectar malas configuraciones de algún equipo.

Características de NTOP

Licencia: Version community Open Source.

Sistemas operativos soportados: Linux, Mac OSX y Windows.

Entre sus funcionalidades están:

- Ordenar tráfico de red acorde determinados criterios
- Muestra tráfico de red e IPV4/V6 hosts activos.
- Produce reportes acerca de métricas de red
- Caracteriza tráfico HTTP.
- Muestra la distribución de tráfico IP entre varios protocolos.
- Analiza tráfico IP y lo ordena acorde a su fuente y destino.
- Reporta el uso de protocolos IP ordenados por su tipo.

- **Athtek netwalk personal edition[77]**

Características

- Licencia: gratuita e ilimitada, versión personal.
- Sistemas operativos soportados: Windows 2003, 2008, XP, Vista, 7 y 8.

- Programa de escritorio que permite monitorear tráfico a través de la red. Brinda estadísticas en forma de torta, barra, gráfica en tiempo real.

Funcionalidades principales:

- Captura de paquetes, especificando puertos y direcciones IP de origen y destino.
- Gráfica Protocolos más recurrentes, incluye DNS, HTTP, FTP, POP3, IMAP, ARP, es configurable.
- Gráficas de ping, distribución de paquetes, broadcast y multicast, TCP vs UDP, protocolos recurrentes.
- Permite programación de capturas por hora y fecha en su inicio y final.
- Es posible integrarlo a Wireshark.

Los criterios para seleccionar el analizador de tráfico son:

- **Funcionalidad:** Permite capturar tráfico IP y guardarlo para la construcción del conjunto de datos. Debe rastrear los flujos RTP de las llamadas de VoIP generadas y extraer información de las mismas, específicamente los parámetros de desempeño de calidad de servicio: retardo, pérdida de paquetes y Jitter.
- **Comunidad de desarrolladores:** Este criterio se refiere al grupo de desarrolladores y personas o entidades que hacen uso de la herramienta. Una comunidad de desarrolladores está calificada de acuerdo a la cantidad de información de experiencias y resultados obtenidos y compartido por todos los desarrolladores. Esta característica es importante en el presente trabajo ya que aporta a la comprensión del funcionamiento y características relevantes del analizador de tráfico además de tener acceso a las experiencias y trabajos relacionados.
- **Compatibilidad con Linux:** El analizador de tráfico captura el tráfico del computador que sirve como central telefónica, equipo que como se explicó en la sesión 3.1.1.1 tendrá el sistema operativo Linux.
- **Documentación:** Brinda información suficiente por parte del desarrollador de la herramienta para comprender las funcionalidades del analizador de tráfico y sacar su máximo provecho. Este criterio es importante para interpretar los datos obtenidos por la herramienta de captura, específicamente de los tres parámetros de desempeño de QoS.

En la Tabla 3-4 se ilustran los resultados obtenidos en la evaluación realizada para selección de la herramienta para el monitoreo del tráfico IP en el entorno de pruebas, donde se asignan valores en un intervalo de 0 a 5, siendo 0 la puntuación más baja y 5 la mejor.

Tabla 3-4. Comparación herramientas de monitoreo.

Criterio	Wireshark	NTOPNG	AthTek
Funcionalidad (40%)	5	4	4
Comunidad (20%)	5	3	3
Compatibilidad Linux (20%)	5	5	0
Documentación (20%)	5	3	3
Resultado	5	3.8	2,8

Teniendo en cuenta los resultados obtenidos se selecciona como herramienta de monitoreo de tráfico Wireshark por cumplir con todos los criterios de selección, mientras que Ath Tek se descarta al estar disponible solo en el sistema operativo Windows y NTOPNG por no suministrar los parámetros de Calidad de Servicio requerido.

3.2 Construcción del conjunto de datos

A continuación, se propone la construcción de un conjunto de datos que describe la estructura del comportamiento general de un servicio de Voz sobre IP bajo determinadas condiciones de tráfico, duración de llamadas y parámetros de desempeño.



Figura 3-2. Esquema general del escenario de prueba.

Para dar cumplimiento al objetivo general se propone el siguiente escenario

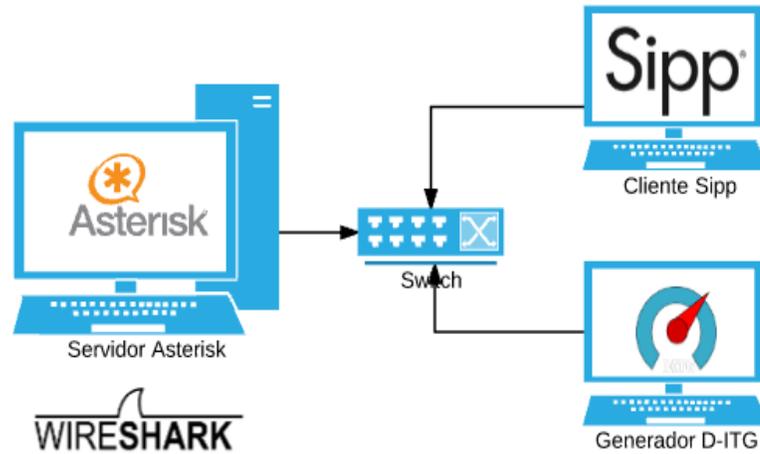


Figura 3-3. Escenario de prueba.

El escenario de pruebas se implementa en la Oficina 115 ubicada en el Centro de postgrados de la Facultad de Ingeniería de Electrónica y Telecomunicaciones de la Universidad del Cauca. La red local del acceso está basada en Ethernet a 100 Mbps y se cuenta con un servidor Asterisk que actúa como central telefónica IP.

Dos computadores se conectan al servidor Asterisk mediante un switch cisco 2650 y un modem utilizando cable de par trenzado; el primero, trabajando como cliente Sipp y el segundo, encargado de generar tráfico IP adicional con D-ITG.

En la tabla 3-5 se ilustran las características de cada equipo.

Tabla 3-5. Características equipos.

Equipo	Sistema operativo	Procesador	Memoria RAM
Servidor Asterisk	Ubuntu 14.04 LTS	Intel Core i7 3,4 GHz x 8	12 GB
Cliente Sipp Generador DITG	Ubuntu 14.04	Intel Pentium 2,8 GHz x 2	4 GB

Sobre este escenario se realizarán varias pruebas y consideraciones técnicas para la extracción de conclusiones referentes a las condiciones que influyen en el establecimiento de las comunicaciones VoIP en el generador de llamadas Sipp

El tráfico de VoIP se utiliza el comando, cuyos parámetros se especifican en la Tabla 3-6:

Sipp -s #exts -sn uac -d duración (ms) -m # -r # -i iplocal ipasterisk

Tabla 3-6. Parámetros comando Sipp.

Variable	Función
-s	Define la extensión a la cual se hará la llamada
-sn	Llama al escenario que se usará por defecto
-d	Duración de la llamada en milisegundos
-m	Número total de llamadas que realiza el cliente
-r	Número de intento de llamadas por segundo
-i	Estable la IP local, la del cliente

Para la generación de los datos es importante definir la incidencia que tienen cada uno de los parámetros del generador de tráfico Sipp, en la capacidad de aceptación de llamadas del servidor Asterisk. Por lo tanto, se realizan diferentes pruebas para determinar el valor idóneo que se debe emplear para cada parámetro:

a. Variación del número de intento de llamadas por segundo y duración de llamada promedio

Tomando como referencia llamadas con duración de 30, 60, 180 y 360 segundos se varia la cantidad de intentos de establecimiento de llamada que el sistema realizará por segundo (10, 15, 20, 25, 30, 50 y 100), para analizar la cantidad de llamadas aceptadas, como se presenta en la Figura 3-4:

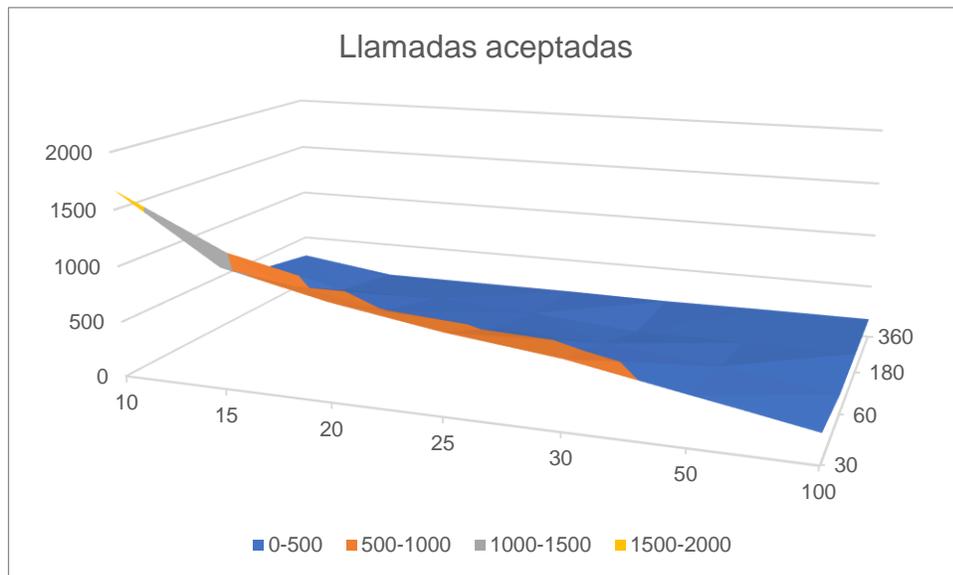


Figura 3-4. Número de intentos de llamada frente a llamadas establecidas.

El eje Z de la gráfica representa la cantidad de llamadas aceptadas, al variar la duración de las llamadas generadas y el número de intentos de establecimiento de llamada; así, al incrementar la duración se aprecia que la cantidad de llamadas aceptadas tiende a ser menor a 500 (zona azul), por otra parte, entre menor sea la cantidad de intentos con llamadas de 30 segundos de duración se tiene entre 1500 a 2000 llamadas establecidas (zona amarilla). A partir de la información obtenida se determina que el número de intentos de llamada que realiza el sistema debe ser bajo.

b. Variación de la duración de la llamada (2 y 3 minutos)

Según la Comisión de Regulación de las Comunicaciones en Colombia, el promedio de duración de una llamada es de 120 a 180 segundos[78], por esta razón inicialmente, se realizan pruebas con los tiempos promedios de las llamadas y se observa que este parámetro no afecta el número de llamadas aceptadas como se muestra a continuación:

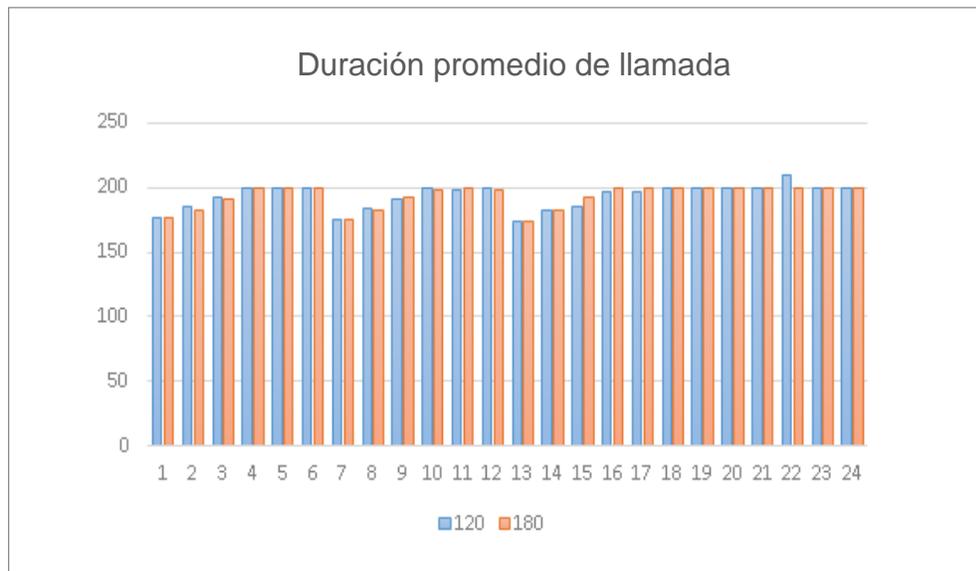


Figura 3-5. Comportamiento de las llamadas con duración promedio.

c. Variación tiempo en un intervalo mayor (30 seg-10min)

- Efecto en el número de llamadas aceptadas

Se repite la Prueba 2, ampliando el intervalo de las muestras de tiempo. Tomando como referencia llamadas con duración fija de 30, 60, 180,360 segundos y un intervalo que varía de 30 a 600 segundos, se realizan pruebas con un número fijo de llamadas realizadas (500), para determinar el impacto de la duración de la llamada en la cantidad de sesiones aceptadas y la condición de las mismas como se presenta en la Tabla 3-7:

Tabla 3-7. Prueba variando la duración de llamada.

Duración(seg)	Realizadas	Aceptadas	Problemas	Llamadas con problemas (%)
30	500	349	7	2,005
60	500	329	29	8,814
180	500	165	24	14,54

360	500	165	33	20
600	500	165	66	40
30-600	500	234	81	34,61

A medida que aumenta la duración de las llamadas disminuye número de sesiones/llamadas aceptadas. Cuando la duración de las llamadas es de 30 o 60 segundos el servidor atiende más de 300 llamadas mientras que para llamadas con duración superior a 180 segundos disminuye el valor a 165 llamadas y se estabiliza. Por otra parte, la herramienta suministra una alerta en las llamadas que clasifica como sesiones con problemas. Es de resaltar que esta característica crece a medida que la duración de la llamada también lo hace, lo que significa que las llamadas de larga duración son más susceptibles a presentar fallos.

Para la construcción del conjunto de datos es importante tener llamadas con condiciones distintas, razón por la cual se decide variar la duración de las llamadas entre 30 y 600 segundos.

- Efecto en los parámetros de desempeño de QoS

Para analizar el comportamiento de los parámetros de desempeño de calidad de servicio se hace uso de medidas estadísticas que proporcionan información sobre la variación de los mismos cuando la duración cambia.

Moda: Suministra información sobre el valor que más se repite dentro de conjunto de datos

Tabla 3-8. Moda de cada parámetro con respecto a la duración de llamada.

Duración(seg)	Lost (%)	Delay (ms)	Max jitter	Mean jitter
30	0,00	21,723	N/A	N/A
60	0,00	20,215	N/A	N/A
180	0,00	21,386	N/A	N/A
360	0,00	1834,0006	N/A	N/A
600	0,00	1334,0000	N/A	N/A

30-600	0,00	1002,0000	N/A	N/A
--------	------	-----------	-----	-----

De la Tabla 3-8 se concluye que la moda del porcentaje de paquetes perdidos corresponde a 0,00%; lo cual indica que con respecto al total de llamadas aceptadas el número que más se repite entre ellas es 0,00% independientemente de la duración de la misma. El retardo oscila entre 20,215 a 21,723 para tiempos de duración de llamadas de 30, 60 y 180 lo cual corresponde a valores bajos de latencia, mientras para duración de llamadas de 360 y 600 son altos (1334,0000-1834,0006).

Tabla 3-9. Media de los parámetros con respecto a la duración de llamada.

Duración(seg)	Lost (%)	Delay (ms)	Max jitter	Mean jitter
30	1,50	336,548504	0,189796845	0,0172788
60	7,39	1164,126055	0,085727759	0,0114595
180	12,11	1164,126055	0,182840264	0,0117145
360	5,59	3264,687709	0,319884431	0,0118942
600	6,76	3637,734208	0,367162934	0,0121497
30-600	15,35	3937,988581	0,142112277	0,0109333

Como se muestra en la Tabla 3-9, a medida que aumenta la duración de la llamada el promedio del retardo también, mientras que los demás parámetros no siguen un patrón. Por ejemplo, cuando la duración de la llamada es 30 segundos el retardo es 336,54 milisegundos, cuando aumenta a 360 segundos la duración es 3264,68 milisegundos y así sucesivamente.

Del análisis estadístico se concluye que el retardo es el parámetro que más se afecta con la variación de la duración de la llamada, además da un indicio de que el conjunto de datos a construir posiblemente presente desbalance, ya que los datos centrales tienden a estar en un intervalo reducido.

d. Dimensionamiento del tráfico externo

En esta prueba se busca dimensionar y clasificar el tráfico adicional producido por el generador D-ITG en tres etiquetas: ALTO, MEDIO y BAJO mediante la analogía de consumo de ancho de banda de algunas aplicaciones para posteriormente emplearlo sobre el tráfico de VoIP y determinar el efecto del mismo.

La Tabla 3-10 ilustra el consumo de ancho de banda aproximado de: Facebook, YouTube y Skype[79]

Tabla 3-10. Dimensionamiento de tráfico cursado por algunas aplicaciones.

Aplicación	Tráfico	Descripción
Facebook	800KB a 1MB	40 historias en las "ultimas noticias" +Chat
YouTube	5 MB-60MB	1 video-5 videos
Skype	252MB	Comunicación través de vídeo

- **Dimensionamiento del tráfico IP**

$$10 \text{ pps} \times 1000 \text{ Bytes} = 10 \frac{\text{KB}}{\text{Seg}}$$

$$10 \frac{\text{KB}}{\text{Seg}} \times \frac{3600 \text{ seg}}{1 \text{ hora}} = 36 \frac{\text{MB}}{\text{H}}$$

Tabla 3-11. Relación proporcional del tráfico cursado en la red.

Aplicación	Tráfico	Descripción
Facebook	$\frac{36 \text{ MB}}{1 \text{ MB}} = 36$	40 historias en las "ultimas noticias" +Chat
YouTube	$\frac{1,6 \text{ GB}}{60 \text{ MB}} = 26,66$	1 video-5 videos

Skype	$\frac{1,6 \text{ GB}}{252 \text{ MB}} = 6,349$	Comunicación través de vídeo
-------	---	------------------------------

Con base a la Tabla 3-11 se define los siguientes valores de tráfico para cada categoría dentro del presente estudio:

- Alto: 1,6 GB/H
- Medio: 540 MB/H
- Bajo: Ausencia de tráfico externo

Consideraciones finales para la generación de los datos

Estas pruebas determinan el efecto individual que produce cada uno de parámetros del generador de llamadas, con base en estos resultados se determina finalmente:

*Sipp -s (n extensión) -sn uac -d (60/120/180...600) -m 2000 -r
(1/2/5/20/50/100) -i ipdestino iporigen*

Y para el generador de tráfico externo:

*./ITGSend -T UDP -a ipdestino -c (100/400/500/900/1000) -C 10
i-t 400000*

La toma de información para la construcción de conjunto final se realizó en un periodo de dos días simulando las tres condiciones de la red:

- Para el tráfico bajo se tomaron 10 pruebas en ausencia de tráfico externo o enviando flujos UDP con tamaño de carga variable de 100 bytes a una tasa de paquete constante de 10 pps durante 4000000 ms, y generando 2000 llamadas (m) por prueba con numero de intentos por segundo menor a 100 (r) y variando la duración de la llamada entre 60 a 600 segundos.
- Para el tráfico medio se tomaron 10 pruebas en presencia de tráfico externo enviando flujos UDP con tamaño de carga variable de 400 y 500 bytes a una tasa de paquete constante de 10 pps durante 4000000 ms, y generando 2000 llamadas (m) por prueba con numero de intentos por segundo menor a 100 (r) y variando la duración de la llamada entre 60 a 600 segundos.

- Finalmente, para el tráfico medio se tomaron 10 pruebas en presencia de tráfico externo enviando flujos UDP con tamaño de carga variable de 900 y 1000 bytes a una tasa de paquete constante de 10 pps durante 4000000 ms, y generando 2000 llamadas (m) por prueba con numero de intentos por segundo menor a 100 (r) y variando la duración de la llamada entre 60 a 600 segundos.

Es importante resaltar que a mayor tráfico menor cantidad de llamadas aceptadas.

3.3 Descripción del conjunto de datos

En la presente sección se hace uso de las dos primeras fases de la metodología CRISP-DM que corresponden a la comprensión del negocio y de los datos, para entender y describir el conjunto de datos a construir.

3.3.1 Fase 1 CRISP-DM: Comprensión del negocio



Es fase es considerada una de las más importantes de este proceso y reúne las tareas de comprensión de los objetivos y requisitos del proyecto desde una perspectiva empresarial o institucional, con el fin de convertirlos en objetivos técnicos y en un plan de proyecto [80] como se presenta en la Figura 3-6, en la cual se identifican:

Objetivos del negocio	<ul style="list-style-type: none"> • Detección de calidad de llamadas. • VoIP en una red de computadores.
Objetivos del Minería de datos	<ul style="list-style-type: none"> • Verificar calidad de Datos. • Generar modelos de clasificación. • Seleccionar el mejor modelo.
Valoración de la situación	<ul style="list-style-type: none"> • 3 parámetros de desempeño. • 2 factores externos.

Figura 3 6. Comprensión del negocio.

3.3.2 Fase 2: Comprensión de los datos



Comprende la recolección inicial de datos, con el objetivo de establecer un primer contacto con el problema, familiarizándose con ellos, identificar la calidad y establecer las relaciones más evidentes que permitan definir las primeras hipótesis [80].

A esta fase están asociados las siguientes tareas:

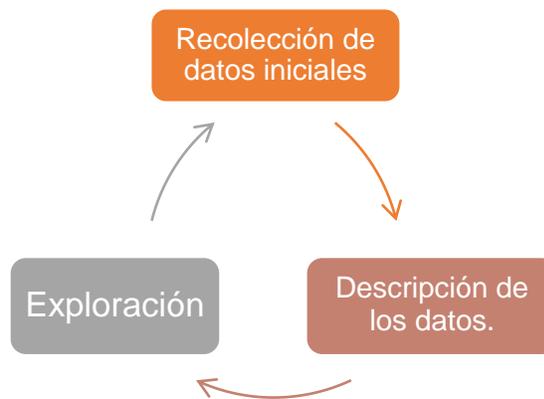


Figura 3-6. Proceso de comprensión de los datos.

3.3.2.1 Recolección de datos iniciales

La obtención de los datos se realiza a través del escenario de pruebas definido en el escenario de pruebas Sección 3.2.

3.3.2.2 Descripción y exploración de los datos

Tabla 3-12. Atributos del conjunto de datos.

Categoría	Atributo	
Condición de la red	Traffic	Etiquetas
Descriptores de la llamada	Source Address	-

	Source Port	-
	Destination Address	-
	Destination Port	-
	SSRC	-
	Packets	#
Parámetros de desempeño	Lost Packets	#
	Lostpcnt	%
	Max Delay	Ms
	Max Jitter	Ms
	Mean Jitter	Ms
Estado de la llamada	Service state	

La Tabla 3-12 muestra los atributos agrupados en cuatro categorías de acuerdo a sus características:

1. *Condición de la Red:* Agrupa los atributos relacionados con el estado de la red.
 - Traffic: Describe la cantidad de tráfico IP adicional por intervalos de tiempo, definido con etiquetas (alta, media, baja).
2. *Descriptores de la llamada:* Contiene los atributos relacionados la información general de cada llamada.
 - Source Address: Describe la dirección IP de donde se origina la llamada.
 - Source Port: Hace referencia al puerto usado por la fuente.
 - Destination Address: Describe la dirección IP de donde de destino.
 - Destination Port: Hace referencia al puerto usado por el destino.
 - SSRC: Fuente de sincronización
3. *Parámetros de desempeño:* Contiene los atributos que describen la calidad de servicio en términos de desempeño:
 - Lost Packets: número de paquetes perdidos

- Lostpcnt: Porcentaje de pérdida de paquetes con respecto al total enviados
- Delay: Retardo por Colas
- Mean Jitter: Variación del retardo promedio
- Max Jitter: Variación del retardo máximo

4. *Estado de la llamada*: Contiene la variable objetivo

- Service_status: Estado del servicio dependiente de la QoS.

El analizador de tráfico Wireshark permite obtener los parámetros de desempeño de QoS, aunque se deben tener en cuenta algunas consideraciones en la extracción de los datos.

- **Consideraciones para el cálculo del retardo**

La recomendación G.114 de la ITU define el retardo como el tiempo de transmisión de un paquete.

El retardo total está compuesto por cuatro tipos de retardo

$$R = R_{trans} + R_{prop} + R_{proc} + R_{cola} \text{ [80]}$$

- *Retardo de transmisión*
- *Retardo de propagación*
- *Retardo de procesamiento*
- *Retardo por colas*

El componente importante a tener en cuenta es el retardo por cola[80], ya que puede variar de un paquete a otro. Por ejemplo, si llegan diez paquetes en una cola vacía al mismo tiempo, el último paquete transmitido sufrirá una cola relativamente grande a diferencia del primero, mientras espera a que se transmitan los otros nueve paquetes.

Los otros tres tipos de retardo añaden un valor despreciable, con respecto al retardo por colas, pero teóricamente se pueden extraer de la siguiente manera:

- *Retardo de Propagación*: Es el tiempo requerido por la señal óptica o eléctrica para viajar a través de un medio de transmisión. La recomendación ITU G.114 brinda pautas para la estimación del retardo de extremo a extremo, permitiendo obtener información para determinar el valor aproximado de mismo como se muestra en la siguiente tabla[81]

Tabla 3-13. Retardo de extremo a extremo.

Sistema de transmisión o de procesamiento	Contribución al tiempo de transmisión	Observaciones
Sistema de cable coaxial terrenal o radioenlace; transmisión FDM y digital	4 μ s/km	Se tiene en cuenta el retardo en repetidores y regeneradores
Sistema de cable de fibra óptica; transmisión digital	5 μ s/km (nota 1)	
Sistema de cable coaxial submarino	6 μ s/km	
Sistema de fibra óptica submarino: – terminal transmisor – terminal receptor	13 ms 10 ms	Caso más desfavorable
Sistema por satélite: – 400 km altitud – 14 000 km altitud – 36 000 km altitud	12 ms 110 ms	Propagación en el espacio exclusivamente (entre estaciones terrenas)
Equipo de modulación o demodulación de canal FDM	0,75 ms (nota 2)	
Sistema móvil terrestre público (PLMS, <i>public land mobile system</i>) – Objetivo 40 ms	80-110 ms	
Codificadores y decodificadores de vídeo de la serie H.260	En estudio (nota 3)	

Según la Tabla 3-13, para el caso del escenario de prueba propuesto, se clasifica como sistema de cable coaxial terrenal o radioenlace que tiene un valor de 4 μ s/km aproximadamente.

- *Retardo de Procesamiento-Retardo de Transmisión:* Tiempo que tarda el transmisor en colocar los bits en el canal y tomar la decisión de encaminar un paquete[80]

Longitud del paquete $L = 1.500 \text{ Bytes} = 12.000 \text{ bits}$ (si es variable se trabaja con el máximo posible)

Tasa de transmisión $R = 100 \text{ Mbps}$

($T_b = 12 \mu\text{seg}$)

Retardo del códec: introduce un valor que hace parte del retardo de transmisión[81]

Tabla 3-14. Retardo correspondiente al codificador.

Tipo de Codificador	Velocidad (kbit/s)	Tamaño de trama (ms)	Retardo unidireccional medio introducido correspondiente al codificador(ms)	Referencia
MIC	64	0,125	0,375	G.711, G.712
MICDA	40	0,125	0,375	G.726, G.727
MICDA	32	0,125	0,375	G.721 (1988), G.726, G.727
MICDA	24	0,125	0,375	G.726, G.727
MICDA	16	0,125	0,375	G.726, G.727
LD-CELP	16	0,625	1,875	G.728
LD-CELP	12,8	0,625	1,875	G.728
CS-ACELP	8	1 0	35	G.729
VSELP	7,95	2 0	60	IS-54-B, TIA

Teniendo en cuenta la Tabla 3-14 el valor de retardo introducido es 0,375 ms ya que se hace uso de un códec G.711

- *Retardo por colas:* Este valor está directamente relacionado con la intensidad de tráfico porque depende de la cantidad cursada en la red.[80]

Tabla 3-15. Valores de retardo a considerar.

Componente	Parámetros	Valor	Consideración
<i>Retardo de Transmisión</i> <i>Retardo de Procesamiento</i>	-L max=1500 B -Códec= g711 -R=100 Mbps	Rt=12 us Rc=0,375 ms	Constante
<i>Retardo de Propagación</i>	Cableada	4 us/km	Constante
<i>Retardo por colas</i>	Depende de la congestión		Variable

La Tabla 3-15 ilustra cada componente junto con su respectivo valor. Para este caso en particular, el retardo de transmisión, el retardo de procesamiento y el retardo de propagación se asumen como constantes e introducen un retardo total de 0,4 ms, (muy bajo) razón por la cual el valor a tener en cuenta es el retardo por colas.

3.4 Fase 3: Preparación de los datos

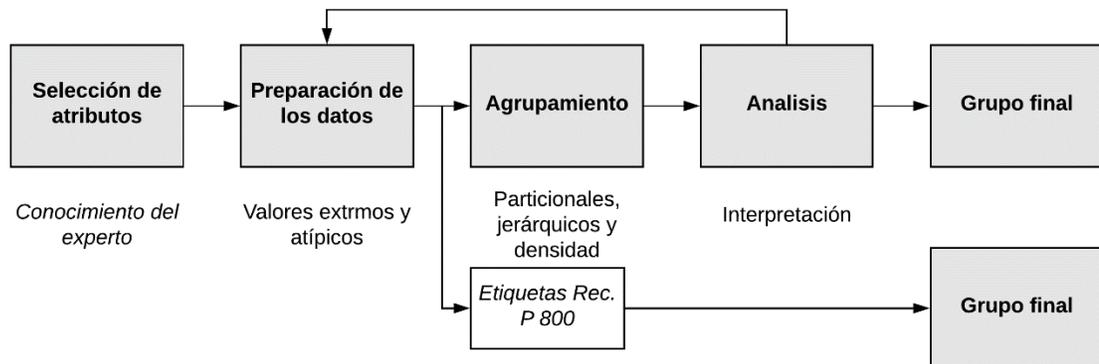


Figura 3-7. Proceso de preparación de los datos.

3.4.1.1 Selección de atributos

La reducción de la dimensionalidad como paso de preprocesamiento para el aprendizaje automático es eficaz para eliminar datos irrelevantes, redundantes y

aumentar la precisión del aprendizaje mejorando la comprensión de los resultados. Existen varios enfoques como el uso de técnicas para reducir la dimensionalidad (filtros/wrapper) o el conocimiento de un experto[82].

En este caso, la utilización de filtros o wrappers[82] no es de gran utilidad ya que estas técnicas proporcionan información que relacionan los atributos del conjunto de datos con la variable objetivo, la cual hasta el momento está en proceso de extracción. Sin embargo, el análisis de cada una de las características relacionadas con el dominio de aplicación resulta eficiente, para eliminar datos innecesarios.

Inicialmente se extraen 19 características con la herramienta de captura de tráfico Wireshark, como se detalló en la fase de comprensión de los datos de la metodología CRISP-DM. Después se realiza el proceso de selección a partir de las siguientes consideraciones:

- Todos los atributos que poseen información repetida: Códec, dirección IP de origen y destino ya que agregan ruido al conjunto de datos y poca información.
- Los atributos que permiten identificar el servicio: SSRC, Source Address, Source Port. Se eliminan ya que desde el inicio del proyecto se determinó trabajar sobre el Servicio de VoIP.
- También se excluyeron los atributos que generan redundancia de información o que pueden ser calculados partir de otros ya existentes: Lost Packets, Packets.
- El atributo Problem se descarta teniendo en cuenta que clasifica las llamadas como problemáticas de acuerdo a criterios que dependen exclusivamente del Servidor Asterisk.

Finalmente, el conjunto de datos quedo constituido por: Traffic, Time, %Lost, Delay, Max Jitter, Mean Jitter.

3.4.1.2 Preparación de los datos:

Una vez seleccionados los atributos relevantes para el presente trabajo, se analizan las instancias; el conjunto de datos inicial cuenta con 26889 instancias.

El primer paso consiste en comparar los valores máximo y promedio de Jitter, teniendo presente que el promedio de un conjunto de datos no es mayor a su máximo se procede a eliminar manualmente cinco instancias, como se presenta en la Tabla 3-16, en la que se observa por ejemplo que cuando el jitter máximo toma un valor de 0.01925 el jitter promedio lo supera con un valor de 0.01999.

Tabla 3-16. Análisis de los valores de Jitter promedio y máximo.

Max Jitter	Mean Jitter
0.019250000004831236	0.01999999995343389
0.01762500000407454	0.095666666670391962
0.013187499997002305	0.01499999999417923
0.019899930372017774	0.020593749995896363
0.014654329308950605	0.026266666688024999

Por otra parte, debido a que la mayoría de los métodos de agrupación son muy sensibles a la presencia de valores atípicos, se aplica el filtro de Weka "InterquartileRange". Al aplicar el filtro a todo el conjunto de datos, éste detecta 2462 valores atípicos, teniendo un primer conjunto de datos con 24422 instancias; sin embargo, es importante revisar si las detecciones del filtro coinciden con valores atípicos o extremos, determinando el rango dentro del cual se encuentran los valores de cada atributo y comparándolos con los valores aportados por las referencias.

A continuación, se presenta los rangos de los datos:

- Retardo: está entre 0 y 9999,76
- Jitter: Máx está entre 0.010437 y 6.03 ms Y Mean está entre 0.003348 y 0.037772 ms
- Pérdida de paquetes: está entre 0 y 1%

De lo anterior se determina que se aplicara el filtro únicamente al atributo "Delta", detectando 282 "Outliers" y teniendo el conjunto de datos final con un total de 26602 instancias.

El siguiente diagrama muestra el proceso anteriormente explicado

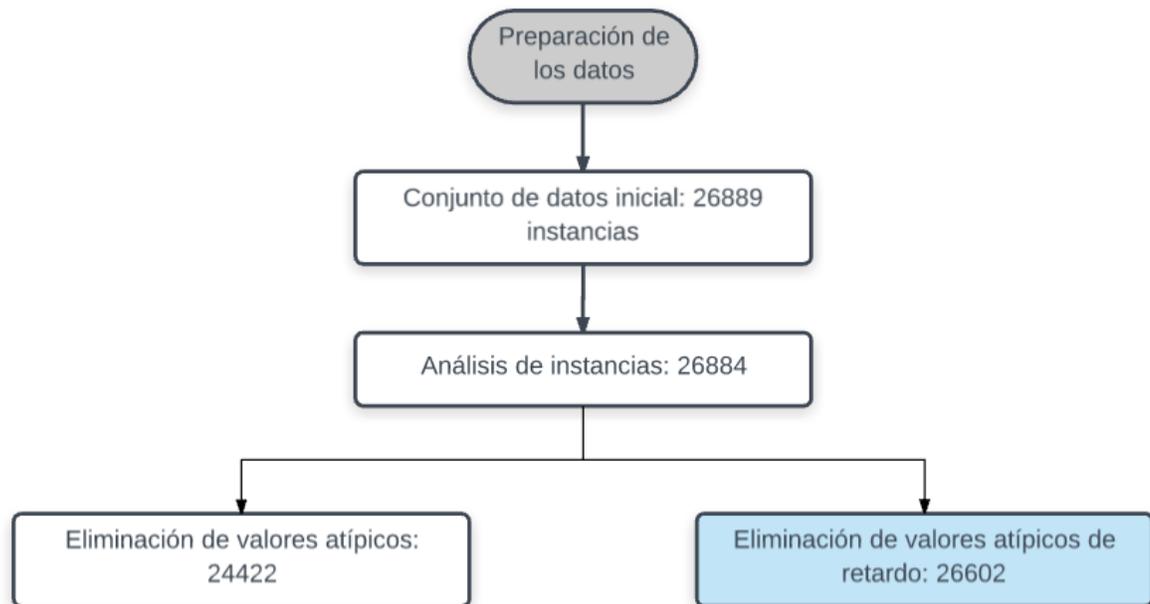


Figura 3-8. Eliminación de valores atípicos

3.4.1.3 Agrupación

El agrupamiento es un modelo descriptivo utilizado para agrupar un conjunto de datos en grupos de acuerdo a sus relaciones. Esta técnica es utilizada en muchos campos como análisis de imágenes, reconocimiento de patrones, análisis de datos estadísticos[83][84]. En nuestro caso, el agrupamiento permitirá encontrar características similares entre los parámetros de desempeño, tráfico externo y duración de las llamadas, las cuales permitan posteriormente relacionar los grupos formados con rangos de calidad de servicio.

Para lograr esto, se analiza la respuesta de tres de los algoritmos de agrupamiento más utilizados: particionales (k-means), jerárquicos (cobweb) y de densidad (DBSCAN)[85]. Después de identificar las diferentes técnicas existentes, se seleccionan los más usados de cada categoría y se procede a aplicarlos, para analizar los beneficios que brinda cada uno en este estudio de caso.

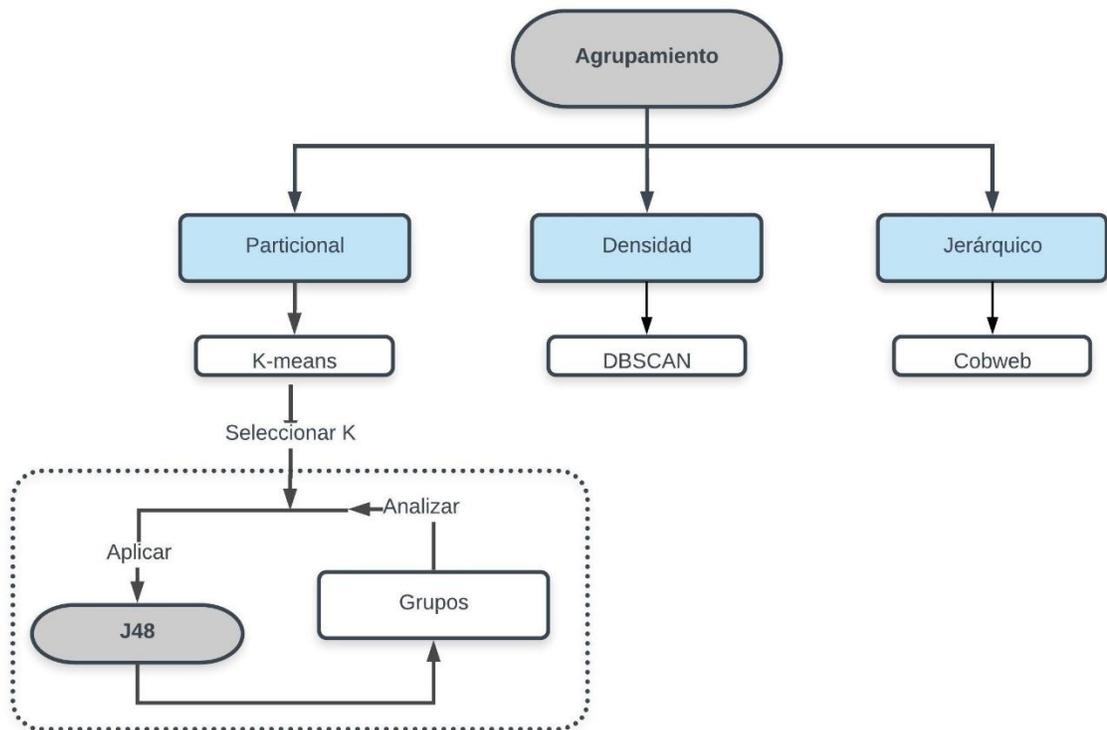


Figura 3-9. Proceso de generación de grupos.

Como lo muestra la Figura 3-10, en la utilización de k-means es necesario seleccionar el valor de k apropiado para definir la variable objetivo del conjunto de datos, se procede a variar la k desde 1 hasta 10, después aplicar J48 (Árbol de decisión) para interpretar las decisiones de cada grupo formado y analizar cuál de ellos brinda mayor información de calidad de servicio. Seguidamente se extraen los datos mostrados en la Tabla 3-17 y el valor de k seleccionado.

Tabla 3-17. Selección del algoritmo de agrupación.

En la Tabla 3-17 se observa que:

- Cobweb genera muchos grupos (55), pero gran parte de ellos no poseen instancias, por lo tanto, no brindan información importante.
- El DBSCAN genera un único grupo, lo que indica que no identifico patrones que le permitieran formar grupos que aporten información al trabajo de grado.
- El mejor comportamiento lo presentó K-Means, con k=3 porque genero grupos con porcentaje de instancias significativo.

Algoritmo	No. De grupos	Porcentaje de instancias del grupo (%)										Tiempo necesario para construir el modelo (seg)	No de interacción	
		0	1	2	3	4	5	6	7	8	9			
Cobweb	55												35.58	
DBSCAN	1												59.42	
K-means	2	74	26										0.17	3
	3	16	13	71									0.13	16
	4	44	13	16	26								0.13	19
	5	28	13	43	0	16							0.28	34
	6	28	5	43	0	15	10						0.28	35
	7	8	5	30	0	15	10	32					0.61	60
	8	11	5	28	2	29	0	15	10				0.68	64
	9	0	5	28	2	12	0	28	10	15			1.39	112
	10	12	4	28	0	13	0	28	7	6	2		1.27	102

3.4.1.4 Análisis

Es importante determinar los patrones que sigue el grupo de llamadas, resultando efectiva la utilización del árbol de decisión, algoritmo que permiten la fácil comprensión y visualización de los criterios de agrupamiento. Partiendo del árbol generado, se analiza las condiciones para cada una de sus ramas y se extraen los rangos de valores generados por el mismo. Es de resaltar que el árbol no tiene en cuenta los valores de Jitter en la toma de sus decisiones, por el contrario, se basa especialmente en los valores de Retardo y Pérdida de paquetes, como se muestra en la Figura 3-11.

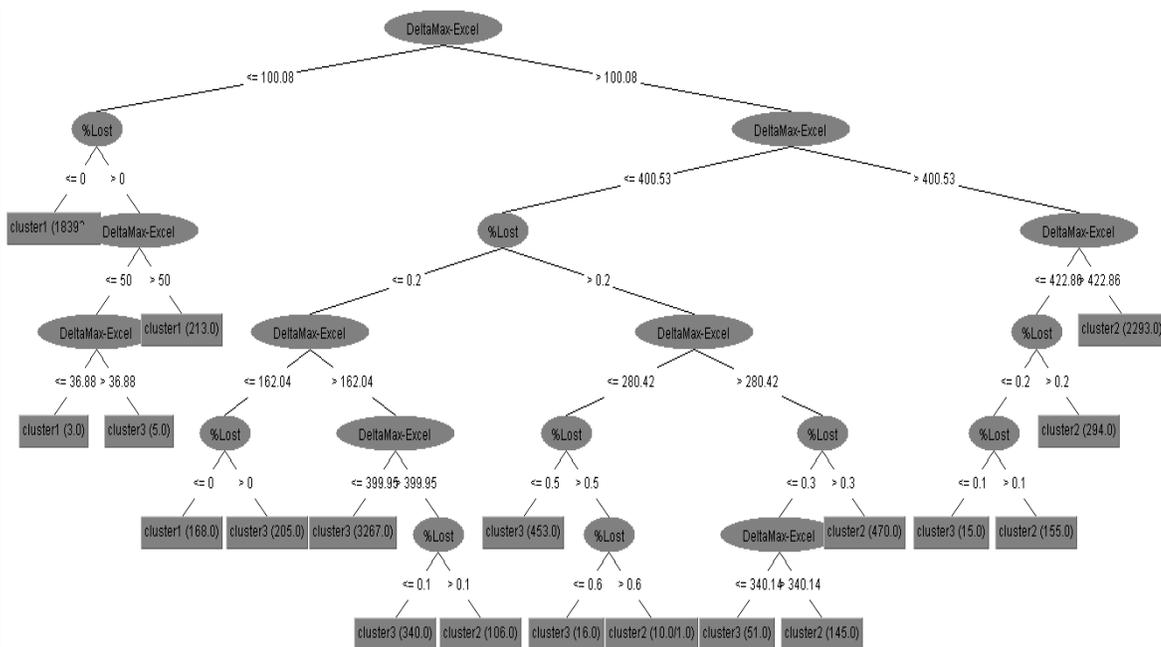


Figura 3-10. Árbol de decisión para el algoritmo de agrupamiento con k=3.

Como se observa en la Tabla 3-18 con los valores generados por árbol de decisión, presentamos una tabla de rangos para los tres parámetros de desempeño de QoS y una evaluación general de cada clúster basada en el Sistema de Medición a través del Análisis por Percepción (Perceptual Analysis Measurement System - PAMS) que determina el grado de calidad del servicio y da una evaluación general cada clúster.

Tabla 3-18. Proceso de análisis del agrupamiento.

Parámetro	Nivel				
	1	2	3	4	5
Retardo	<100	<150	<200	<400	>=400
Jitter	<2.5	<5	<25	<50	>50
Pérdida de paquetes	0	<1	<2	<3	>3

A cada uno de los valores de los parámetros se le asigna un nivel, que posteriormente se suman para ser asociados con una categoría de calidad de servicio, que está asociado a un valor de MOS, como se muestra en la Tabla 3-19.

Tabla 3-19. Relación de los parámetros de calidad con MOS.

Suma de niveles	Categoría	MOS equivalente
<4	Excelente	>4
4-6	Bueno	>3
6-8	Aceptable	>2
8-10	Deficiente	>1
=>10	Inaceptable	<1

En la Figura 3-12 se muestra la distribución final de los grupos generados y asociados a un nivel de servicio (excelente, bueno, aceptable, deficiente, inaceptable). Cada uno de los grupos tuvo una marcada tendencia a clasificarse en una de las cinco posibles categorías. Las gráficas de la izquierda representan los grupos formados al aplicar K-means con $k=3$ y los de la derecha, la distribución de los datos según la recomendación Y.1541 de la ITU, donde se especifican niveles de calidad dependiendo de los parámetros de desempeño de QoS. Es de resaltar que los grupos formados por el algoritmo tienen un comportamiento muy similar al de la recomendación, resultado importante puesto que indica que la técnica utilizada agrupa las llamadas basándose en la calidad sin intervención externa.

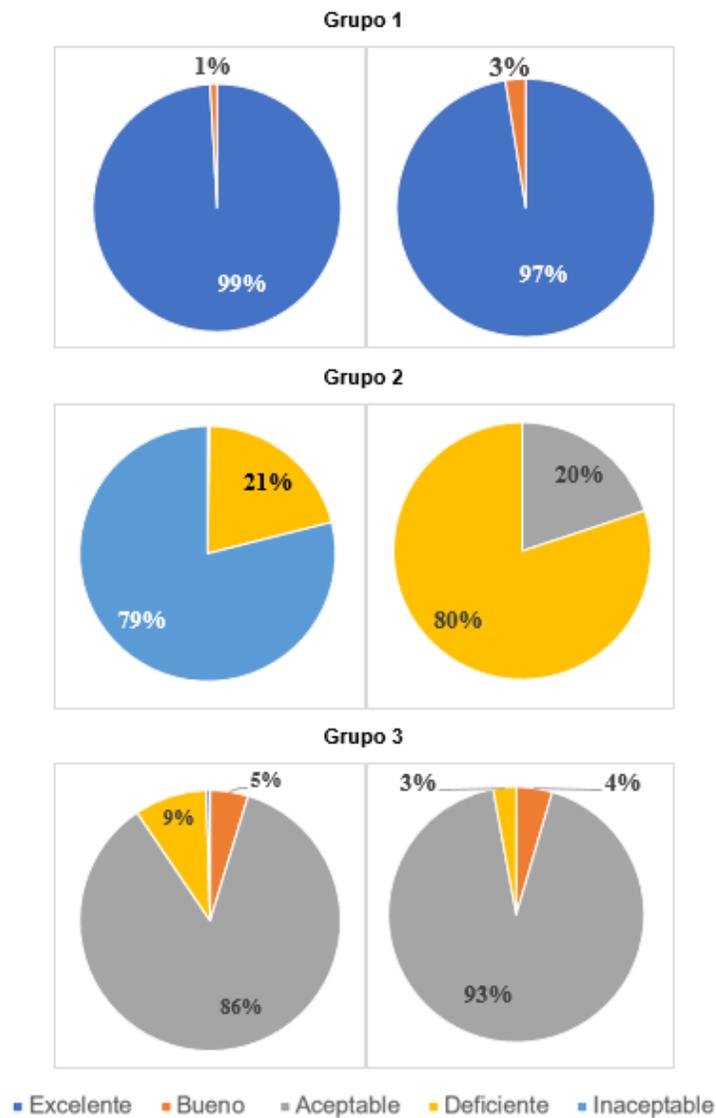


Figura 3-11. Comparación entre grupos aplicando K-Means y los etiquetados con REC-Y.1541.

3.4.1.5 Balanceo de clases

El desbalance en los datos hace referencia a una situación en la que el número de observaciones no es el mismo para todas las clases en un conjunto de datos usado para clasificación. En algunas áreas es común tener datos desbalanceados como por ejemplo en la detección de fraude o el diagnóstico de enfermedades raras, donde la mayoría de los casos pertenecen a la clase “No-Fraude” o “No-Detección”. [86][87]

Al igual que los anteriores ejemplos, en una red de telecomunicaciones el desempeño de la red es normalmente bueno, razón por la cual uno de los grupos generados contiene la mayoría de casos.

Antes de iniciar la fase de modelado se hace necesario enfrentar el desbalance entre las clases del conjunto de datos. Existen diferentes técnicas que permiten disminuir este efecto, entre ellas se encuentra el sobremuestreo “oversampling” que aumenta el número de instancias de las clases minoritarias, y el submuestreo “undersampling” que elimina instancias consideradas redundantes. Para balancear el conjunto de datos construido y evitar que los algoritmos queden sobreentrenados, se aplican tres técnicas (con su implementación en WEKA: SMOTE [88], Reensampling, Random Undersampling). Después de analizar las pruebas se decide que el SMOTE es la técnica más apropiada ya que genera nuevos datos mediante interpolación, sin afectar el comportamiento inicial del conjunto de datos y manteniendo la naturaleza de los mismos.

Tabla 3-20. Variación del número de ejecuciones de SMOTE

Número de ejecuciones	Grupo 1	Grupo 2	Grupo 3	Total de instancias
1	18777	4353	6944	30074
2	18777	8706	6944	34427
3	18777	8706	13888	41371
4	18777	17412	13888	50077
5	18777	17412	27776	63965

La Tabla 3-20 muestran el número de instancias totales al aplicar la técnica de SMOTE. Se decide realizar tres ejecuciones sobre el conjunto de datos para disminuir el efecto del desbalance entre clases y no generar desproporcionadamente datos sintéticos que alteren la estructura del conjunto de datos original. Después de la aplicación del SMOTE se pasa de 26602 a 41371 instancias.

En conclusión, con la selección de las herramientas adecuadas y la implementación del escenario de prueba se construyó el conjunto de datos constituido con información de llamadas sometidas a diferentes condiciones de tráfico externo, duración de llamadas y número de intento de llamadas por segundo. Seguidamente se aplicó un proceso de preparación de los datos para obtener valores confiables y

se hizo uso del algoritmo de agrupamiento K-Means con el objetivo de encontrar patrones dentro del conjunto de llamadas y relacionarlas con rangos de calidad de servicio, obteniendo como resultado 3 grupos que se constituyen como la variable objetivo. Por último, se aplica balanceo de clases utilizando SMOTE para disminuir el sobre-entrenamiento de los algoritmos en la fase de modelado.

Finalmente, el conjunto de datos quedo constituido por 41371 instancias y 6 atributos: tráfico (alto, medio, bajo), duración de la llamada (seg), paquetes perdidos (%), retardo (ms), jitter máximo (ms), jitter promedio (ms).

4 Capítulo: Modelado

En este capítulo se seleccionan las técnicas de modelado más apropiadas para el proyecto, las cuales suelen ejecutarse en múltiples iteraciones. Normalmente, los analistas de datos ejecutan varios modelos utilizando los parámetros por defecto y los ajustan para hacer las manipulaciones necesarias en su modelo [89]; a partir de los resultados obtenidos se realiza la comparación de las técnicas utilizadas analizando precisión, matriz de confusión y test de significancia estadística.

4.1.1 Selección de la técnica de modelado

Con el fin de encontrar la técnica más apropiada para el proyecto se prueba con los algoritmos de Aprendizaje Supervisado para clasificación más utilizados en la literatura, redes bayesianas (BN), arboles de decisión (DT), redes neuronales (NN) y máquinas de vector de Soporte (SVM) [18].

Existen varios métodos de evaluación para establecer el grado de bondad de los algoritmos, según las necesidades del dominio de aplicación como lo son el tiempo de ejecución, el tiempo de aprendizaje y la precisión entre otros. Para nuestro caso resulta relevante el análisis de la precisión de los algoritmos puesto que a partir de los resultados obtenidos se puede extraer información para la generación de las políticas, sin importar cuanto tarde el algoritmo en generar esa respuesta; la información debe ser confiable.

4.1.2 Generación del plan de prueba.

Una vez seleccionados los modelos, se genera el procedimiento para probar la calidad y validez del mismo; en este caso, como es una tarea supervisada de clasificación, es común ejecutar el modelo de entrenamiento y prueba. Se separan los datos en dos conjuntos, uno de entrenamiento y otro de prueba, para construir el modelo basado en el conjunto de entrenamiento y medir la calidad del modelo generado con el conjunto de prueba [90]

Se hizo uso de cuatro técnicas de aprendizaje supervisado, redes neuronales (NN), arboles de decisión (j48), máquinas de vector de soporte (SVM) y redes bayesianas (BN) [18]. En el experimento se varió del 10% al 60% la cantidad de

datos utilizados para el entrenamiento y el resto en pruebas, como se muestra a continuación:

En las Tablas 4-1,4-2,4-3,4-4 los términos CC y CI corresponden al número de instancias clasificadas correcta e incorrectamente, tanto para la sección de entrenamiento (T), de prueba (S) y de validación cruzada (V).

Tabla 4-1. Prueba de entrenamiento: Máquina de vector de soporte.

SVM	Entrenamiento			Prueba			Validación Cruzada(10)		
	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
% Entrenamiento									
10	4019	118	97,1477	36210	1023	97,2524	18474	142	99,2372
20	8197	77	99,0694	32871	225	99,3202	16448	100	99,3957
30	12300	111	99,1056	28703	256	99,116	14382	97	99,3301
40	16435	113	99,3171	24646	176	99,291	12313	98	99,2104
50	20584	101	99,5117	20583	102	99,5069	10238	104	98,9944
60	24698	124	99,5004	16469	79	99,5226	8133	141	98,2959
			99,03553333			98,984567			99,0453167

Tabla 4-2. Prueba de entrenamiento: Árbol de decisión.

DT/J48	Entrenamiento			Prueba			Validación Cruzada(10)		
	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
% Entrenamiento									
10	4136	1	99,9758	37218	15	99,9597	18606	10	99,9463
20	8272	2	99,9758	33079	17	99,9486	16539	9	99,9456
30	12409	2	99,9839	28944	15	99,9482	14471	8	99,9447
40	16546	2	99,9879	24808	14	99,9436	12401	2	99,9194
50	20682	3	99,985	20672	13	99,9372	10336	6	99,942
60	24816	6	99,9758	16542	8	99,9637	8271	3	99,9637
			99,9807			99,9477833			99,94765

Tabla 4-3. Prueba de entrenamiento: Red neuronal.

NN	Entrenamiento			Prueba			Validación Cruzada(10)			
	% Entrenamiento	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
	10	4136	1	99,9758	37228	5	99,9366	18611	5	99,9731
	20	8274	0	100	33091	5	99,9849	16546	2	99,9879
	30	12411	0	100	28954	5	99,9827	14478	1	99,9931
	40	16548	0	100	24816	6	99,9758	12405	6	99,9517
	50	20684	1	99,9952	20677	8	99,9613	10338	4	99,9613
	60	24820	2	99,9919	16541	7	99,9577	8261	13	99,8429
				99,99785			99,9849167			99,9821667

Tabla 4-4. Prueba de entrenamiento: Redes bayesianas.

BN	Entrenamiento			Prueba			Validación Cruzada(10)			
	% Entrenamiento	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
	10	4068	69	98,3321	36636	597	98,3966	18290	326	98,2488
	20	8114	160	98,0662	32562	534	98,3865	16304	244	98,5255
	30	12197	214	98,2757	28489	470	98,377	14257	222	98,4667
	40	16287	261	98,4228	24425	397	98,4006	12192	219	98,2354
	50	20367	318	98,4627	20351	334	98,3853	10154	188	98,1822
	60	24423	399	98,3926	16291	257	98,4469	8146	128	98,453
				98,4293			98,7362833			98,7483

Las Tablas 4-1, 4-2, 4-3, 4-4 muestra los resultados de precisión del conjunto de datos de entrenamiento (con cada porcentaje asignado) y prueba para cada uno de los algoritmos seleccionados. Además, se aplica la técnica de validación cruzada utilizada para evaluar los resultados garantizando la independencia entre datos de

entrenamiento y prueba. Así mismo, para cada sección se identifican la cantidad de instancias clasificadas correcta e incorrectamente por prueba realizada.



El esquema anterior presenta los porcentajes más altos, obtenidos en el plan de pruebas y organizados de menor a mayor en términos de precisión.

Con el objetivo de comprender los resultados obtenidos se utilizan diferentes herramientas de comparación de algoritmos suministrados por Weka: matriz de confusión, análisis de precisión y test de significancia estadística [91][92] con el objetivo de verificar mediante conceptos matemáticos qué algoritmo arroja un mejor comportamiento.

- **Matriz de confusión**

Una matriz de confusión es una herramienta que permite visualizar el desempeño de un algoritmo que se emplea en aprendizaje supervisado. Las columnas de la matriz representan el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real.[93]

La alta precisión en un clasificador no siempre implica que este sea bueno; en ocasiones cuando existe una clase mayoritaria, el algoritmo tiende a clasificar todas las instancias en la clase predominante con una precisión del 99% aproximadamente, pero con un error del 100% en las otras clases. El comportamiento ideal es el de una matriz diagonal, la cual está formada de elementos nulos tanto por encima, como por debajo, de la diagonal principal.

En este caso la diagonal principal corresponde a las llamadas clasificadas correctamente, por lo cual entre menos valores se tenga fuera de la misma, mejor será la precisión del clasificador. Las matrices que aparecen a continuación corresponden a las 4 técnicas de modelado aplicadas:

Tabla 4-5. Matriz de confusión: Redes neuronales.

	Grupo 1	Grupo 2	Grupo 3
Grupo 1	7537	0	0

Grupo 2	0	5544	0
Grupo 3	0	0	3467

De las 16548 llamadas de los tres grupos generados, el 100% fueron clasificadas correctamente en cada uno de los ellos. A partir de la matriz se puede ver que el sistema no tiene problemas distinguiendo entre los diferentes grupos al emplear las Redes Neuronales como clasificador.

Tabla 4-6. Matriz de confusión: Árbol de decisión.

	Grupo 1	Grupo 2	Grupo 3
Grupo 1	7535	0	2
Grupo 2	0	5544	0
Grupo 3	2	1	3463

Al utilizar el árbol de decisión como clasificador, se obtiene que de 7537 llamadas etiquetadas como Grupo 1 reales, el sistema predijo que el 99,973% pertenecían a este, 0,026% al Grupo 3 y 0 al Grupo 2. De 3467 llamadas etiquetadas como Grupo 3 reales, el sistema predijo incorrectamente solo 3 llamadas mientras que las pertenecientes al grupo Grupo 2, acertaron en su totalidad. A partir de la matriz se puede ver que el sistema no presenta tantos problemas distinguiendo entre Grupo 1 y 3 lo que no representa una falla significativa.

Tabla 4-7. Matriz de confusión: Redes bayesianas.

	Grupo 1	Grupo 2	Grupo 3
Grupo 1	7523	1	13
Grupo 2	0	5511	33
Grupo 3	1	221	3245

De 7537 llamadas etiquetadas como Grupo 1 reales, el sistema predijo incorrectamente el 0.18%, de 5544 llamadas del Grupo 2 el 0,59% y de 3467 del Grupo 3 el 6.4%, este último valor cobra importancia teniendo en cuenta el total de instancias del servicio.

Tabla 4-8. Matriz de confusión: Máquinas de vector de soporte.

	Grupo 1	Grupo 2	Grupo 3
Grupo 1	7531	0	6
Grupo 2	0	5544	0
Grupo 3	2	76	3389

La matriz de confusión muestra un comportamiento casi ideal para Grupo 1 y Grupo 2 a diferencia del Grupo 3, en el cual el 2,25% fue clasificado incorrectamente.

- **Análisis de precisión**

Se estiman las métricas de precisión [94]

- **Recall /Precision:** Es la relación entre las observaciones predichas correctamente y el total de observaciones.
- **TP Rate:** Está definido por las instancias que pertenecen a una clase y son clasificadas correctamente. Presenta mejor comportamiento cuando es cercana a 1.
- **FP Rate:** Está definido por las instancias que no pertenecen a una clase, pero son clasificadas en ella. Presenta mejor comportamiento cuando es cercana a cero.

Tabla 4-9. Análisis de precisión.

	SVM	NN	DT	BN
Recall	0,995	1,000	1,000	0,984
Precision	0,995	1,000	1,000	0,984
TP rate	0,995	1,000	1,000	0,984
FP rate	0,003	0,000	0,000	0,008

A partir de lo anteriormente mostrado se puede concluir que en términos de precisión los algoritmos que presentan un mejor comportamiento son las redes neuronales seguidos de los árboles de decisión porque los valores de precisión/Recall y TP rate son más cercanos a 1 y FP rate toman valores cercanos a 0.

- **Test de significancia estadística**

En estadística, un resultado o efecto es estadísticamente significativo cuando es improbable que haya sido debido al azar. Una "diferencia estadísticamente significativa" solamente significa que hay evidencias estadísticas de que hay una diferencia; no significa que la diferencia sea grande, importante o radicalmente diferente[95][96].

- **Test de significancia estadística utilizando T-test (Implementación en weka)**

El término significancia estadística en este caso se refiere al resultado de una comparación por pares de esquemas que usan una T-Test estándar o la T-Test muestreada[97].

Este procedimiento extrae un subconjunto x del esquema a analizar y lo compara con un subconjunto y de la otra técnica con la cual se desea comparar. Posteriormente calcula la diferencia entre cada par de observaciones y halla el promedio de esta.

La Tabla 4-10 muestra el promedio de la precisión de los subconjuntos generados por cada esquema. Mientras que la Tabla 4-11 presenta la diferencia entre cada par de algoritmos.

Tabla 4-10. Promedio precisión.

	NN	DT	SMV	BN
Promedio	99.961	99.915	99.043	96.233

Tabla 4-11. Diferencia del promedio de precisión.

	NN	DT	SMV	BN
NN	--	0.046	0.918	3.728
DT	-0.046	--	0.872	3.682
SMV	-0.918	-0.872	--	2.81
BN	-3.728	-3.682	-2.81	--

El test arrojó que las redes neuronales son estadísticamente mejores que los otros tres esquemas de aprendizaje con un nivel de significancia de 0.05. Los arboles de decisión con respecto a las redes neuronales presentan una diferencia ± 0.046 , inferior al valor de referencia razón por la cual también es considerado estadísticamente significativo.

Entre los dos mejores resultados NN y DT, las NN siguen presentando un mejor comportamiento, aunque existe una diferencia mínima, esta cobra importancia de acuerdo al requerimiento específico. En este caso, para porcentajes altos de entrenamiento, la precisión es casi la misma razón por la cual se considera que ambos algoritmos son buenos, de no ser así es preferible el uso de NN.

Además, se realizaron dos pruebas más que refuerzan los resultados estos resultados:

- **Ranking**

La prueba de Ranking clasifica los esquemas según el número total ganadas (>) y pérdidas (<) significativas contra los otros esquemas. La primera columna (> - <) es la diferencia entre la cantidad de victorias y la cantidad de pérdidas.

Tabla 4-12. Ranking Test.

Algoritmo	Diferencia(>-<)	Ganancia(>)	Perdidas(<)
NN	3	3	0
DT	1	2	1
SVM	-1	1	2
BN	-3	0	3

Esta diferencia se usa para generar el ranking la cual pone en primer lugar las redes neuronales nuevamente.

- **Summary test**

Tabla 4-13. Summary Test.

Algoritmo	NN	SVM	BN	DT
NN	-	0(0)	0(0)	0(0)
SMV	1(1)	-	0(0)	1(1)
BN	1(1)	1(1)	-	1(1)
DT	1(1)	0(0)	0(0)	-

Esta prueba genera una tabla que permite comparar un algoritmo y analizar si los otros tienen un nivel de significancia estadística importante con respecto a él. Los que toman valor 1 adquieren importancia con respecto al algoritmo analizado.

La utilización de la matriz de confusión, ranking y summary test arrojaron que NN presenta el mejor comportamiento, los demás algoritmos no son estadísticamente significativos según los datos obtenidos. La aplicación de estas pruebas da una visión general del comportamiento de los algoritmos, pero se hace necesaria la interpretación de los resultados obtenidos desde nuestro dominio de aplicación.

4.1.3 Comprensión de los resultados obtenidos

En el análisis del comportamiento de los modelos de predicción es importante identificar la naturaleza de los datos de entrenamiento (nominales o numéricos) ya que estos influyen en la respuesta de los mismos. Si son nominales se tiene en cuenta la probabilidad de que un objeto pertenezca a una determinada clase; si son datos numéricos se analiza el valor del atributo y el valor predicho por el clasificador. [98].

Para entender mejor el comportamiento de los algoritmos se generan dos pruebas más

1) Precisión VS tiempo de respuesta

Aunque en la generación de las Políticas de QoS no es relevante el tiempo de ejecución, a manera de ejemplo se aplican los 4 algoritmos para registrar los tiempos de ejecución y los porcentajes de precisión, y comprender mejor los resultados.

Tabla 4-14. Precisión y tiempo de respuesta de los algoritmos.

	Precisión (%)	Tiempo de ejecución(ms)
NN	99,9879%	324,28
DT	99,9855%	3,48
SMV	99,5286%	29,1
BN	98,3756%	0,84

La Tabla 4-14 muestra que NN tarda 324,28 segundos con una precisión de 99,9879%, DT 3,48 segundos y 99,9855% de precisión, SVM 29,1 segundos con una precisión de 99,5286% y BN 0,84 segundos y 98,3756% de precisión.

2) Conjunto de datos con 4 y 6 atributos

El conjunto de datos I de 4 atributos contiene exclusivamente los parámetros de desempeño de QoS mientras que el conjunto de datos II, adiciona dos atributos más que corresponden a la cantidad de tráfico en la red y la duración de las llamadas, parámetros relevantes en la generación de las políticas. Teniendo en cuenta que

las dos características adicionales se pueden analizar dentro o fuera del conjunto de datos se procede comparar la precisión que arroja cada uno de ellos para concluir con cual es más óptimo trabajar. Al igual que en la sección 4.1.2 se aplica la metodología de entrenamiento y prueba variando el conjunto de entrenamiento de 10 a 60%. A manera de ejemplo en la Tabla 4-15 presentamos los resultados obtenidos cuando el conjunto de datos de entrenamiento es 20%, ya que para el resto de pruebas tienen un comportamiento similar

Tabla 4-15. Comparación de la precisión los dos conjuntos de datos

	Conjunto de Datos I	Conjunto de Datos II
NN	99,98	99,98
DT	99,94	99,96
SMV	99,2361	99,32
BN	98,3865	98,7733

A partir de los resultados de la sección 4.1.2 y de las dos anteriores pruebas se concluye para cada algoritmo lo siguiente:

- **Redes neuronales**

En la implementación el Multilayer Perceptron reprocessa las instancias con el filtro denominado “nominalToBinaryFilter”. Esto ayuda a mejorar el rendimiento de los algoritmos si hay presencia de atributos nominales en los datos. Internamente cuando se normalizan los atributos, también se aplica a los valores nominales de modo que estén entre -1 y 1.[99]

Cada atributo nominal, se adjunta a una neurona en la capa de entrada. Si hay n valores, n neuronas serán necesarias, cada una de ellas con un conjunto de entradas permitido: {0, 1} o {-1, 1}.

Para nuestro caso, el Grupo 2 se codifica como 0.333, Grupo 3 como 0.666 y Grupo 1 como 1; siendo el intervalo permitido de [0, 1]. La mayor desventaja del proceso realizado es que conduce a una gran capa de entrada aumentando los tiempos de

ejecución, pero con una alta precisión [100] . Al ejecutar la prueba de precisión y tiempo de respuesta se observa que NN requiere más tiempo de ejecución (324,28 seg) pero obtiene la mayor precisión (99,9879%).

Teniendo en cuenta que el conjunto de datos está constituido por atributos tanto nominales como numéricos, es necesario realizar el proceso de normalización lo que aumenta el tiempo de ejecución, pero mejora la precisión. Esto no constituye un problema para este dominio de aplicación puesto que se requiere confiabilidad de los datos para la generación de las políticas de QoS y no velocidad en la obtención de los mismos[101].

- **Árbol de decisión – J4.8**

Teóricamente trata de forma indiferente los atributos nominales y numéricos. Al ejecutar la prueba de precisión y tiempo de respuesta, el árbol de decisión obtiene una alta precisión (99,9855%) en un tiempo bajo (3,48 seg), aunque NN lo supera en precisión tarda aproximadamente 93 veces más en ejecutarse y mientras que BN presenta menor tiempo de respuesta, disminuye la precisión en 1,6123%.

En el caso de que el tiempo de ejecución y la precisión tuvieran la misma importancia para la generación de políticas, DT sería la mejor opción. [102]

- **Máquina de vector de soporte - SMO**

Esta implementación reemplaza globalmente todos los valores perdidos y transforma los atributos nominales en binarios. Al implementar una forma similar al de la red neuronal, en la normalización de los datos obtiene también un alto desempeño[99].Al igual que DT tiene un equilibrio entre tiempo de ejecución y precisión, Aunque NN lo supera en 0,4593% de precisión aparentemente un porcentaje bajo de diferencia, en la clasificación de grandes cantidades de datos puede generar un efecto negativo e impresión en toma de decisiones para la generación de políticas.

- **Red bayesiana**

De manera experimental se observó que al utilizar redes bayesianas en el conjunto de datos II que contiene tanto atributos nominales como numéricos se obtuvo una precisión de 98.3865% mientras que en el conjunto de datos II donde no existen atributos nominales se alcanzó un 98,7733% mejorando en 0,3868%

Se repitió el mismo procedimiento con los otros tres algoritmos: Árboles de decisión pasó de 99,94% a 99,96% (0,02), Redes Neuronales se mantuvo en 99,98%(0) y máquinas de vector de soporte de 99,32% a 99%(0.08). (Anexo A)

Estos resultados permiten extraer dos conclusiones del porqué las redes bayesianas presentan el peor comportamiento para este estudio de caso:

- Son susceptibles a los atributos que introducen ruido en la clasificación
- La presencia de atributos nominales disminuye la precisión en la clasificación notablemente.

5 Capítulo: Definición de políticas

Este capítulo presenta el análisis de los datos para proponer un mecanismo de control de admisión de llamadas, basado en la definición de políticas. Inicialmente se muestra el funcionamiento general del sistema implementado en este trabajo de grado, con el objetivo de proporcionar al administrador de red una ayuda en la gestión de la misma; en segundo lugar, se exponen conceptos importantes en el marco del planteamiento de políticas, y finalmente se contextualiza en un escenario.

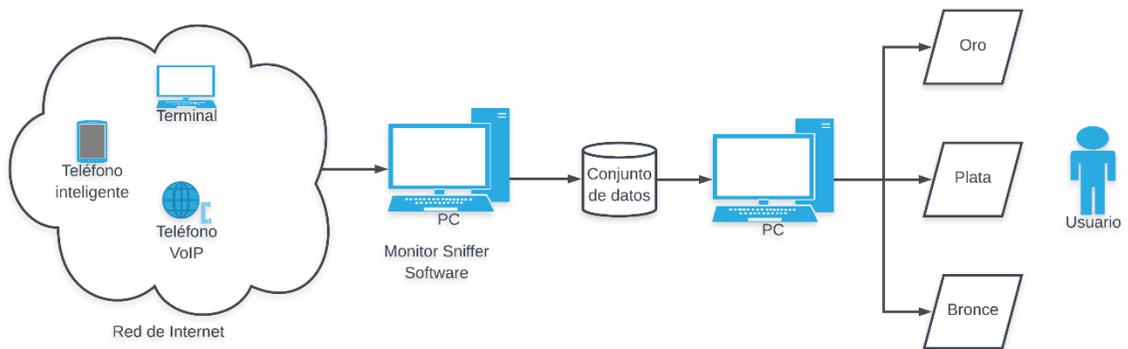


Figura 5-1. Arquitectura del sistema.

Mediante un analizador de protocolos se extrae información sobre el estado actual de la red para construir el conjunto de datos que se entrega al modelo de clasificación, dicho modelo clasifica los datos en tres grupos: Oro, Plata y Bronce; por su parte el administrador procede a configurar el servidor de Asterisk para recibir la cantidad de llamadas que pueda soportar con la Calidad de Servicio requerida, rechazando las llamadas que no cumplan los requisitos mínimos. A continuación, se explica el proceso y conceptos importantes del mecanismo propuesto.

5.1 Definición SLA

Los Acuerdos de Nivel de Servicio definen la relación entre el proveedor de servicios y cliente, para establecer formalmente expectativas y obligaciones que existen en su relación comercial.

Muchos enfoques actuales para especificar Acuerdos de Nivel de Servicio, en particular para servicios de red, se realizan especificando parámetros de calidad de servicio tales como retardo, pérdida de paquetes, Jitter, tasas de error y disponibilidad entre otros. La especificación del servicio es esencialmente estática ya que a menudo asume un único tipo de servicio proporcionado en todo momento, pero muchos clientes requieren servicios que varían según la fecha o la hora[103]

Un proveedor de servicios puede proporcionar un conjunto de servicios, que se ofrecen a una organización-cliente que consta de muchos usuarios diferentes. No todos los usuarios de una organización cliente pueden necesitar acceso a todos los servicios ofrecidos.

Un acuerdo de nivel de servicio por lo general tiene un período de duración que se especifica en el acuerdo. Todos los servicios que se incluyen en el acuerdo se describen y también pueden contener detalles sobre los procedimientos para supervisar el desempeño de los servicios.

Tener un SLA permite transparencia sobre cuáles son los objetivos de nivel de servicio, así como lo que sucede si los objetivos requeridos no se cumplen. Con un acuerdo de nivel de servicio ambas partes están protegidas.

5.1.1 Tipo de SLA (Nivel de servicio)

Las entidades pueden escoger el servicio de acuerdo con una combinación de variables según sus necesidades.[104]

Los servicios ofrecidos pueden ser Bronce, Plata y Oro, dependiendo de tres factores:

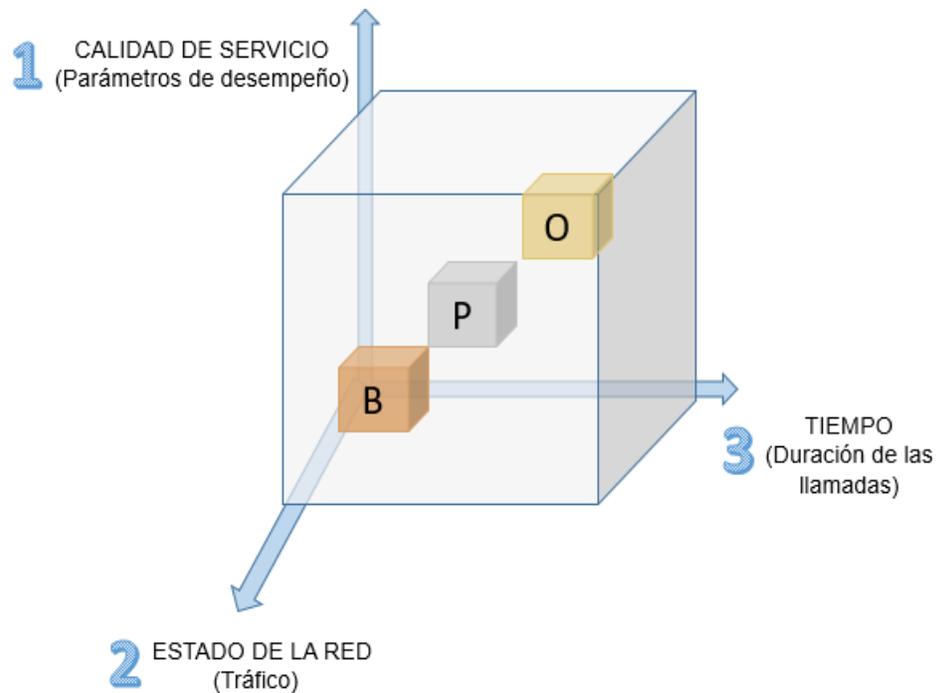


Figura 5-2. Servicios ofrecidos.

5.1.1.1 Calidad de Servicio

A partir del Sistema de Medición a través de Análisis por Percepción y los valores sugeridos por la UIT en su Rec. Y.1540 [105] se establecen las siguientes categorías: Excelente, Bueno, Aceptable, Débil e Inaceptable.

NOTA: Con el conjunto de datos del presente trabajo se detectan tres categorías como se explica en la sección 3.4.1.4: Excelente, aceptable e inaceptable.

5.1.1.2 Estado de la red

La condición de una red varía en el tiempo dependiendo del tráfico que cursa a través de ella. En este escenario de prueba se simula estados alto, medio y bajo de tráfico IP para analizar su incidencia en el comportamiento del servicio de voz sobre IP. Este experimento pretende asemejar la estructura del comportamiento de una red, en un contexto real, donde interactúan diferentes tipos de servicios, que afectan el funcionamiento ideal de la red.

5.1.1.3 Tiempo

El tiempo de las llamadas cambia dependiendo de los requerimientos del Cliente; sin embargo, la Comisión de Regulación de las Comunicaciones establece una duración promedio entre dos y tres minutos.

5.1.2 Definición de política

Especificaciones de Nivel de Servicio (ENS) que en conjunto constituyen el Acuerdo de Nivel de servicio (ANS) [3]

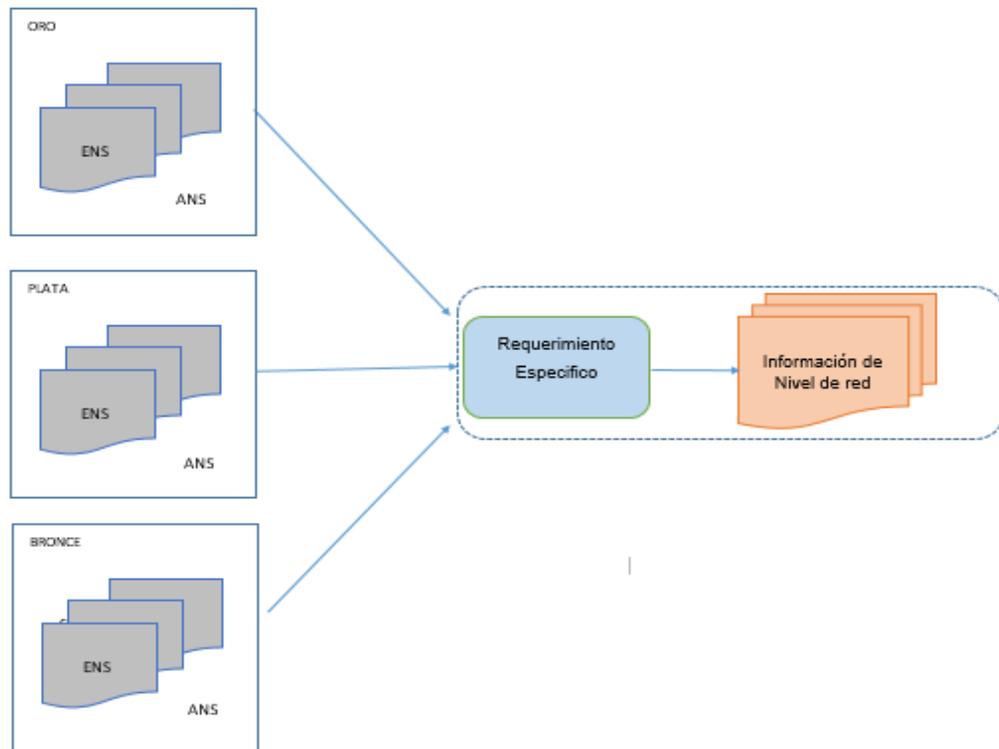


Figura 5-3. Definición de políticas.

La Figura 5-3 describe los tipos de servicio a implementar dependiendo de los requerimientos del usuario para condiciones de red específicas[3]

Tabla 5-1. Resumen políticas.

Clúster	Id	Política	Retardo	Pérdida	Tráfico	Tiempo
Oro	ENS1	Política1	<100,08	= 0	Medio/Bajo	<= 3 min
	ENS2	Política2	>50,0 <=100,08	<= 0.2	Alto	= 1 min
	ENS3	Política3	>100,08 <=162,04	= 0	Alto/Medio/Bajo	0 - 10 min
Plata	ENS4	Política4	>162,04 <399,95	<= 0.2	Alto/Medio	<= 6 min
	ENS5	Política5	>100,08 <=280,42	>0,2 <=0,5	Alto	= 1 min
	ENS6	Política6	>100,08 <=162,04	<= 0.1	Medio	= 4 min
Bronce	ENS7	Política7	> 422.86	<= 0,8	Alto	> 3 min y <= 6 min
	ENS8	Política8	>280.42 <=400.53	>0,3 <=1	Alto	<= 3 min
	ENS9	Política9	>400.53 <=422.86	<=0,3	Alto	<= 6 min

PDB: Per Domain Behavior

Escenario ejemplo

Se toma como escenario para la ejemplificación de las políticas un Campus universitario compuesto por diferentes tipos de usuarios como se muestra a continuación:

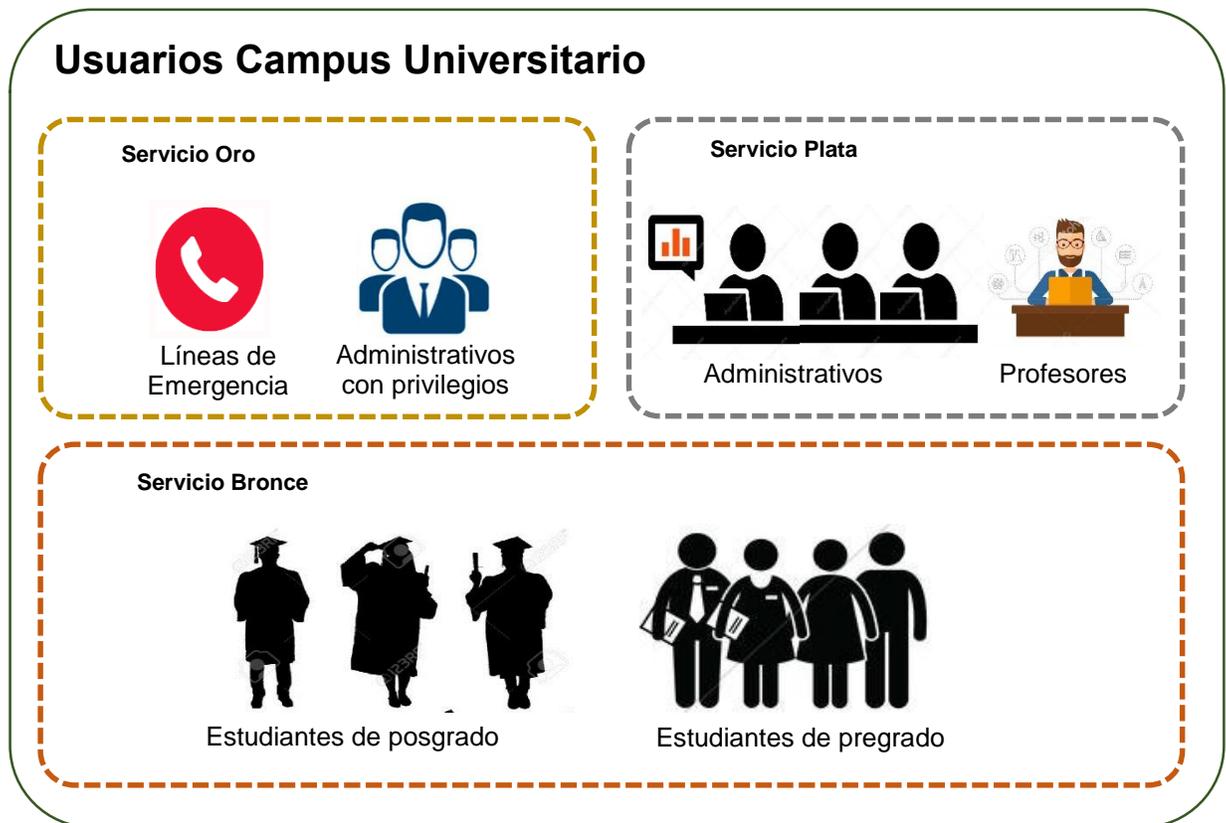


Figura 5-4. Escenario ejemplo: Campus universitario.

Dentro de los actores que hacen parte de este ecosistema se encuentran los administrativos, profesores y estudiantes. Cada uno de ellos con requerimientos específicos en el uso del servicio de VoIP.

De acuerdo a las funciones que desempeña en la universidad se clasifican en una categoría para la prestación del servicio.

A partir de la información presentada en la Tabla 5-1 se definen las políticas en la sección 5.1.2.1, 5.1.2.2 y 5.1.2.3.

5.1.2.1 ORO

Política 1: Si el tráfico generado por otros servicios es medio o bajo, el retardo es menor o igual a 100 ms y no hay pérdida de paquetes, las llamadas entrantes tendrán una duración menor o igual a 3 minutos.

Política 2: Si el tráfico generado por otros servicios es alto, el retardo es menor o igual a 100 ms y la pérdida de paquetes es menor o igual a 0,2, las llamadas entrantes tendrán una duración menor o igual a 1 minuto.

Política 3: Independientemente del tipo de tráfico adicional en la red, si el retardo es mayor a 100,8 ms, pero no supera los 162 ms, y la pérdida de paquetes es nula, no se limitará la duración de las llamadas (1-10 min).

Ejemplo:

En un campus universitario existen tipos de usuario que requieren alta prioridad ya sea porque el estado así lo exige o sus funciones dentro de la institución lo requieren:

- Las Líneas de Emergencia: son extensiones que requieren prioridad ya que son utilizadas en casos donde se ve involucrada la integridad y seguridad de los estudiantes. Por esta razón es de suma importancia su disponibilidad durante las 24 horas del día, los 365 días del año y la prestación de servicio de llamadas con excelente Calidad. Este tipo de líneas de atención están abiertas a la toda la comunidad en general, razón por la cual en situaciones de desastres presentan alta demanda.
- Administrativos con privilegios: Hacen parte de este grupo el rector, los vicerrectores, jefes de dependencia quienes reciben o realizan llamadas en las cuales los temas a tratar son de vital importancia y requieren alta calidad.

El servicio Oro es ideal para este tipo de escenario ya que trabaja bajo cualquier condición de tráfico en la red, sin limitaciones de tiempo y afectaciones considerables en la calidad de las llamadas.

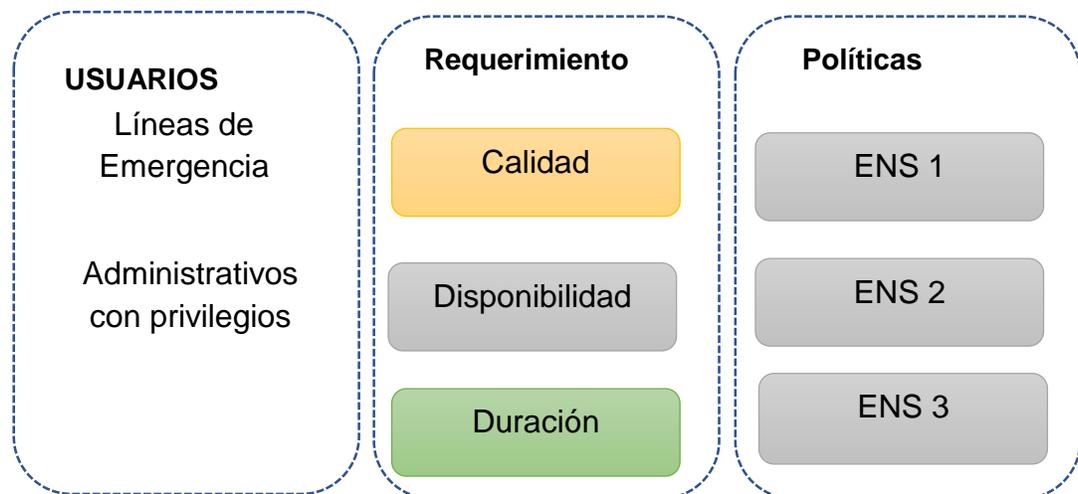


Figura 5-5. Servicio oro: Usuarios, requerimientos y políticas

5.1.2.2 PLATA

Política 4: Si el tráfico generado por otros servicios es alto, el retardo no supera los 400 ms, la pérdida de paquetes es inferior o igual a 0.2%, las llamadas tendrán una duración menor o igual a 6 minutos

Política 5: Si tráfico generado por otros servicios es alto, el retardo es mayor a 100 ms y menor a 280 ms, la pérdida de paquetes es mayor a 0.2% y menor o igual a 0.5%, las llamadas tendrán una duración menor o igual a 1 minuto.

Política 6: Si tráfico generado por otros servicios es medio, el retardo es mayor a 100 ms y menor a 162 ms, las llamadas tendrán una duración menor o igual a 4 minutos.

Los trabajadores de la universidad que ejercen sus funciones durante la jornada laboral colombiana (8:00 am -12:00 m y 2:00 pm - 6:00 pm) son usuarios que a nivel interno utilizan servicios de telefonía, correo electrónico, navegación, entre otros lo que hace que durante algunos periodos de tiempo la red se congestione, afectando la prestación de los servicios en tiempo real como VoIP. Por esta razón es necesario en algunos casos restringir la duración de las llamadas para que no superen los 6 minutos y se pueda satisfacer la demanda. Hacen parte de este grupo los administrativos y profesores.

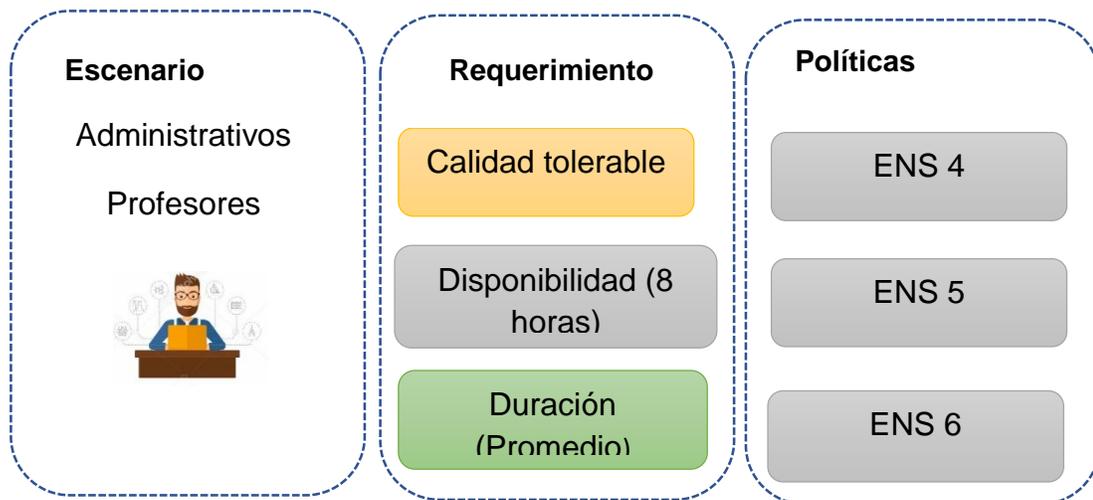


Figura 5-6. Servicio plata: Usuarios, requerimientos y políticas

5.1.2.3 BRONCE

Política 7: Si el tráfico generado por otros servicios es alto y el retardo es mayor a 422 ms, las llamadas entrantes tendrán una duración menor o igual a 6 minutos.

Política 8: Si el tráfico generado por otros servicios es alto, el retardo es mayor a 280 ms y menor a 400 ms, las llamadas tendrán una duración menor o igual a 3 minutos.

Política 9: Si el tráfico generado por otros servicios es alto, el retardo es mayor a 400 ms y menor a 422 ms, la pérdida de paquetes es menor a 0,3%, las llamadas tendrán una duración menor o igual a 6 minutos.

Ejemplo

Un campus Universitario es un lugar donde se reúnen gran cantidad de estudiantes que comparten la misma red, por la que cursan diferentes tipos de aplicaciones que generan gran cantidad de tráfico, razón por la cual garantizar servicios en tiempo real con calidad es difícil.

En este escenario es preferible prestar servicios como el de navegación o correo electrónico antes de las llamadas de VoIP. En caso de realizarse la llamada solo se aceptará bajo las condiciones de la política 8, de lo contrario la llamada será rechazada porque es preferible negar el servicio que prestarlo con baja calidad.

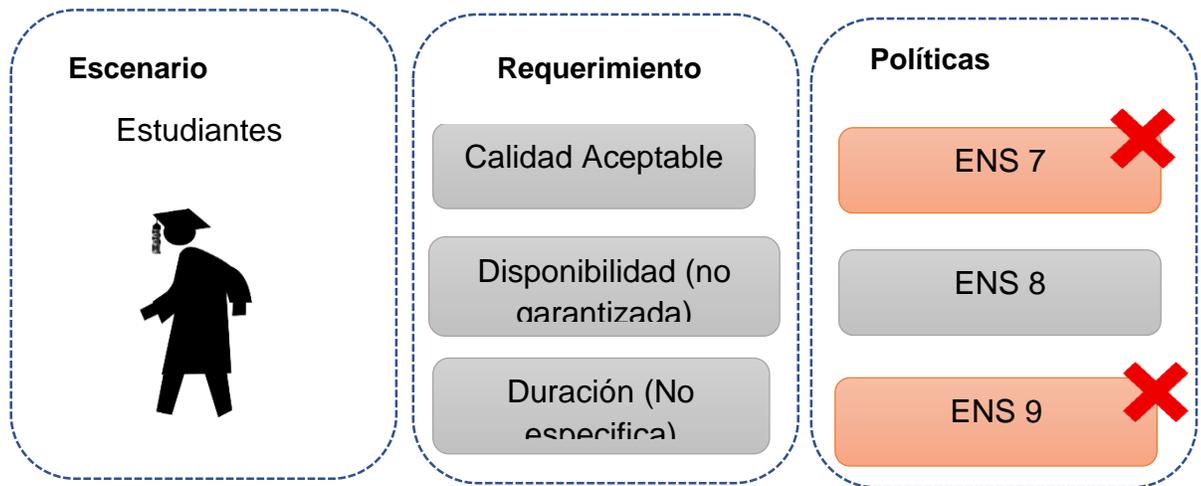


Figura 5-7. Servicio bronce: Usuarios, requerimientos y políticas

6 Capítulo: Conclusiones y trabajos futuros

Este capítulo presenta las conclusiones obtenidas a lo largo del desarrollo de este trabajo de grado además de algunos posibles trabajos futuros, con el propósito de generalizar las conclusiones obtenidas y servir como base para que continúe con esta línea de investigación.

6.1 Conclusiones

- Después de una exhaustiva revisión documental y análisis de los trabajos relacionados con esta investigación se concluye que, a pesar de la existencia de mecanismos para el control de admisión de llamadas en las redes convencionales, no hay uno que se aplique en la voz sobre IP para garantizar calidad de servicio.
- El proceso de selección y caracterización de diferentes herramientas para la construcción del conjunto de datos basado en criterios de selección de software, de acuerdo a los objetivos del proyecto, concluye que las opciones más apropiadas son:
 - Asterisk como central de telefonía IP por ser una plataforma vigente, estable, en continuo mejoramiento y con amplia documentación.
 - Sipp ya que modela condiciones y criterios específicos de una sesión de voz cercana a la realidad.
 - DITG como generador de tráfico IP porque crea flujos simulando las diferentes aplicaciones que interactúan en una red de datos (video, correo y navegación).
 - Wireshark como analizador de tráfico ya que permite capturar los parámetros de desempeño de las llamadas de VoIP.

- El análisis de las medidas estadísticas permitió concluir que el parámetro de desempeño más afectado, al estar expuesto a un tráfico externo y la variación en la duración de las llamadas, fue el retardo seguido por la pérdida de paquetes, observación importante a partir de la cual se genera la clasificación de las llamadas según su calidad.
- Con base en el Sistema Perceptivo de Medida (PAMS), se etiqueta con cinco categorías el conjunto de datos generado, de las cuales tres se encuentran presentes y coinciden en su mayoría con los grupos generados automáticamente al aplicar el algoritmo K-means.
- En el presente trabajo se obtuvo un conjunto de datos desbalanceado, condición normal por el dominio de aplicación en el que desarrolla. El SMOTE fue la técnica que permitió disminuir el efecto negativo que produce esta condición al sobre entrenar los algoritmos y obtener resultados imprecisos.
- La aplicación de algoritmos de agrupamiento para la detección de grupos asociados a la calidad de las llamadas fue muy útil ya que permitió generar niveles de QoS e identificar políticas aplicables a diferentes escenarios según las condiciones de la red y requerimientos de los usuarios.
- Las redes neuronales presentan el mejor comportamiento, debido a que realizan un proceso de conversión de datos nominales a numéricos, aunque aumenta el tiempo de respuesta, mejora la precisión de la clasificación.
- Las redes bayesianas presentan el rendimiento más bajo para este estudio de caso; comparando la respuesta del clasificador al ser entrenado con el conjunto de datos de cuatro y seis atributos, éste disminuyó su precisión en aproximadamente 0,4%, mientras que los demás clasificadores no arrojaron una variación significativa.

- El mecanismo de Control de Admisión de Llamadas basado en políticas, permite al administrador de red identificar la condición actual de la red y los requerimientos del usuario para la gestión eficiente de los recursos de la red.

6.2 Trabajos futuros

Considerando el área de investigación de proyecto, se proponen los siguientes trabajos futuros.

- Realizar un estudio similar para el servicio de video para proponer políticas para el control de admisión de video (VAC).
- Implementar el prototipo experimental en un escenario real, integrándolo a la topología de una Universidad para validar la aplicación de las políticas y su rendimiento.
- Realizar un estudio similar en una red que soporte más servicios, como navegación y correo, y comparar los resultados con los del presente trabajo.
- Generar una interfaz web para que el administrador de la red pueda configurar las políticas.
- Construir un conjunto de datos dentro de una organización en la que se categorice los usuarios y se incluyan datos de día y hora para determinar proponer un control de admisión de llamadas dinámico.
- Realizar un procedimiento similar para la obtención de las políticas combinando diferentes tecnologías alámbricas e inalámbricas que permitan obtener un modelo general independiente de la tecnología de acceso.
- Utilizar algoritmos híbridos para comparar los resultados con los obtenidos en este trabajo de grado.
- Utilizar redes virtualizadas para la extracción de los datos, analizar el comportamiento de estas redes y comparar los resultados.

- Implementar las políticas propuestas y analizar la calidad percibida por el usuario (QoE).

7 Referencias

- [1] J. C. Duque-Jaramillo and E. M. Villa-Enciso, "Big Data: desarrollo, avance y aplicación en las Organizaciones de la era de la Información," *Rev. CEA*, vol. 2, no. 4, p. 27, 2017.
- [2] P. Louridas and C. Ebert, "Machine Learning," *IEEE Softw.*, vol. 33, no. 5, pp. 110–115, 2016.
- [3] L. Lymeropoulos, E. Lupu, and M. Sloman, "An Adaptive Policy Based Framework for Network Services Management," *J. Netw. Syst. Manag.*, vol. 11, no. 3, pp. 277–303, 2003.
- [4] L. Lymeropoulos, E. Lupu, and M. Sloman, "An Adaptive Policy Based Management Framework for Differentiated Services Networks," no. October, pp. 1–12, 2002.
- [5] E. Soler Palacín, "Diseño e implementacion de una solucion de VOIP," pp. 1–154, 2009.
- [6] Z. Liu, "Gridifying teleco-services for NGN service convergence," *2009 IFIP/IEEE Int. Symp. Integr. Netw. Manag. IM 2009*, pp. 253–256, 2009.
- [7] S. Yaram, "Machine Learning Algorithms for Document Clustering and Fraud Detection," *2016 IEEE Int. Conf. Data Sci. Eng.*, 2016.
- [8] S. Gangadhar and J. P. G. Sterbenz, "Machine Learning Aided Traffic Tolerance to Improve Resilience for Software Defined Networks," pp. 9–11, 2017.
- [9] G. G. Sundarkumar, V. Ravi, and V. Siddeshwar, "One-class support vector machine based undersampling: Application to churn prediction and insurance fraud detection," *2015 IEEE Int. Conf. Comput. Intell. Comput. Res.*, no. ii, pp. 1–7, 2015.
- [10] A. D. E. L. Protocolo, "UIT-T," 2006.
- [11] ITU-T, "Uit-T Y.2001," p. 18, 2004.
- [12] E. Perez "Utilización de la tecnología voz sobre ip dentro de una red" pp. 9066–9071, 2014.
- [13] D. L. M. Murillo, "Sistema de Voz sobre IP en una Red de Infraestructura Mesh para Gestión de Emergencias," pp. 18-21-32, 2013.
- [14] W. S. González, "Potocolos de señalización usada actualmente para terminales móviles e IP," 2011.
- [15] UNAM, "UNAM - Facultad de Ingeniería Biometría Informática," pp. 1–151,

2016.

- [16] M. Fernanda and B. Almeida, "Evaluación de los Parámetros que Afectan la Calidad de Servicio en Telefonía IP * Evaluation of Parameters Affecting the Quality of Service (QoS) in IP Telephony," no. 17, pp. 61–71, 2015.
- [17] Itu-T, "Y.1541 Network performance objectives for IP-based services.," *Ser. y Glob. Inf. Infrastructure, Internet Protoc. Asp. Next-Generation Networks Internet Protoc. Asp. – Qual. Serv. Netw. performance.*, p. 66, 2011.
- [18] D. C. Corrales, "Toward detecting crop diseases and pest by supervised learning," *Ing. y Univ.*, vol. 19, no. 1, p. 207, 2015.
- [19] N. Li, "Resource and Admission Control in NGN Co-editor of Y . RACF," no. October, pp. 3–5, 2006.
- [20] G. Networks, "ITU-T," 2006.
- [21] Y.-X. Meng, "The practice on using machine learning for network anomaly intrusion detection," *2011 Int. Conf. Mach. Learn. Cybern.*, vol. 2, pp. 576–581, 2011.
- [22] W. Li and W. Meng, "An Empirical Study on Email Classification Using Supervised Machine Learning in Real Environments," pp. 9066–9071, 2015.
- [23] S. Umarani and D. Sharmila, "Predicting Application Layer DDoS Attacks Using Machine Learning Algorithms," vol. 8, no. 10, pp. 1785–1790, 2014.
- [24] J.-M. Wang, C.-L. Qian, C.-H. Che, and H.-T. He, "Study on Process of Network Traffic Classification Using Machine Learning," *2010 Fifth Annu. ChinaGrid Conf.*, no. 60776096, pp. 262–266, 2010.
- [25] K. Singh and S. Agrawal, "Comparative analysis of five machine learning algorithms for IP traffic classification," *2011 Int. Conf. Emerg. Trends Networks Comput. Commun.*, pp. 33–38, 2011.
- [26] a Bashar, "Modeling and Evaluation of Machine Learning Based Network Management System for NGN," *Adv. Inf. Netw. Appl. Work. (WAINA), 2013 27th Int. Conf.*, pp. 1473–1478, 2013.
- [27] A. Karageorgos, D. Avramouli, C. Tjortjijis, and G. Ntalos, "Agent-based digital networking in furniture manufacturing enterprises," *Commun. Comput. Inf. Sci.*, vol. 88 CCIS, no. PART 2, pp. 381–395, 2010.
- [28] A. Bashar, G. Parr, S. McClean, B. Scotney, and D. Nauck, "Machine learning based call Admission Control approaches: A comparative study," *Proc. 2010 Int. Conf. Netw. Serv. Manag. CNSM 2010*, pp. 431–434, 2010.
- [29] J. Chen, Y. Zou, and Y. Wang, "Wireless Capsule Endoscopy Video Summarization : A Learning Approach Based on Siamese Neural Network and

Support Vector Machine,” 2016.

- [30] L. Cruz and M. Acevedo, “Reconocimiento de Voz usando Redes Neuronales Artificiales Backpropagation y Coeficientes LPC,” no. 978-607-0-165–9, p. 89, 2008.
- [31] T. Bujlow, T. Riaz, and J. M. Pedersen, “A method for classification of network traffic based on C5.0 machine learning algorithm,” *2012 Int. Conf. Comput. Netw. Commun. ICNC’12*, pp. 237–241, 2012.
- [32] S. A. Qureshi, A. S. Rehman, A. M. Qamar, A. Kamal, and A. Rehman, “Telecommunication subscribers’ churn prediction model using machine learning,” *Eighth Int. Conf. Digit. Inf. Manag. (ICDIM2013)*, pp. 131–136, 2013.
- [33] K. M. Thilina, N. Saquib, and E. Hossain, “Machine Learning Techniques for Cooperative Spectrum Sensing in Cognitive Radio Networks,” *IEEE J. Sel. Areas Commun.*, vol. 31, no. 11, pp. 2209–2221, 2013.
- [34] J. R. Chandrakant and D. L. Shashikant, “Machine learning based internet traffic recognition with statistical approach,” *India Conf. (INDICON), 2013 Annu. IEEE*, pp. 1–6, 2013.
- [35] W. Zhou, L. Dong, L. Bic, M. Zhou, and L. Chen, “Internet traffic classification using feed-forward neural network,” *2011 Int. Conf. Comput. Probl.*, pp. 641–646, 2011.
- [36] S. Dong, D. Zhou, and W. Ding, “The Study of Network Traffic Identification Based on Machine Learning Algorithm,” *2012 Fourth Int. Conf. Comput. Intell. Commun. Networks*, pp. 205–208, 2012.
- [37] Y. Wang, Y. Xiang, and S. Yu, “Internet Traffic Classification Using Machine Learning: A Token-based Approach,” *2011 14th IEEE Int. Conf. Comput. Sci. Eng.*, pp. 285–289, 2011.
- [38] J. Erman, A. Mahanti, and M. Arlitt, “Internet Traffic Identification using Machine Learning,” *Glob. Telecommun. Conf. 2006. GLOBECOM ’06. IEEE*, pp. 1–6, 2006.
- [39] N. Namdev, S. Agrawal, and S. Silkari, “Recent advancement in machine learning based internet traffic classification,” *Procedia Comput. Sci.*, vol. 60, no. 1, pp. 784–791, 2015.
- [40] V. S. Mahajan and B. Verma, “Implementation of Network Traffic Classifier using Semi Supervised Machine Learning Approach,” pp. 6–8, 2012.
- [41] A. Testolin *et al.*, “A machine learning approach to QoE-based video admission control and resource allocation in wireless systems,” *IEEE IFIP Annu. Mediterr. Ad Hoc Netw. Work.*, no. JUNE 2014, pp. 31–38, 2014.
- [42] A. Roshdy and A. Gaber, “Radio Resources Dimensioning Using Machine

Learning with case study in Live Network.”

- [43] N. Piedra and J. López, “Estudio de la Aplicación de Redes Neuronales Artificiales en la Ingeniería de Tráfico de Internet.”
- [44] L. Gong, J. Wang, X. Zhang, and K. Lei, “Intelligent Forwarding Strategy Based on Online Machine Learning in Named Data Networking.,” *Trustcom/BigDataSE/ISPA*, pp. 1288–1294, 2016.
- [45] L. H. Do and P. Branch, “Real Time VoIP Traffic Classification,” *Communications*, no. July, pp. 1–3, 2009.
- [46] F. S. R. Barrientos, “Aplicación de Minería de Datos para Predecir Fuga de Clientes en la Industria de las Telecomunicaciones,” *Rev. Ing. Sist.*, vol. XXVII, pp. 73–108, 2013.
- [47] A. I. Kokkinaki, “On atypical database transactions: Identification of probable frauds using machine learning for user profiling,” *Proc. IEEE Knowl. Data Eng. Exch. Work. KDEX*, pp. 107–113, 1997.
- [48] U. Paul, A. Kashyap, R. Maheshwari, and S. R. Das, “Passive measurement of interference in WiFi networks with application in misbehavior detection,” *IEEE Trans. Mob. Comput.*, vol. 12, no. 3, pp. 434–446, 2013.
- [49] L. Kriara, M. K. Marina, and A. Farshad, “Characterization of 802.11n wireless LAN performance via testbed measurements and statistical analysis,” *2013 IEEE Int. Conf. Sensing, Commun. Networking, SECON 2013*, pp. 158–166, 2013.
- [50] W. Li and A. Moore, “A machine learning approach for efficient traffic classification,” ... , *Anal. Simul. Comput. ...*, pp. 310–317, 2007.
- [51] J. Luis Rivero Pérez, R. Rodríguez, C. Rodas, and C. Correo-e, “Técnicas de aprendizaje automático para la detección de intrusos en redes de computadoras Machine learning techniques for intrusion detection in computer networks,” vol. 8, no. 4, pp. 2227–1899, 2301.
- [52] “Análisis de algoritmos de aprendizaje automático para la caracterización de usuarios de la Web,” pp. 1–50, 2015.
- [53] J. M. Fossaceca, T. A. Mazzuchi, and S. Sarkani, “MARK-ELM: Application of a novel multiple kernel learning framework for improving the robustness of network intrusion detection,” *Expert Syst. Appl.*, vol. 42, no. 8, pp. 4062–4080, 2015.
- [54] M. Mirza, “A Machine Learning Approach To Problems in Computer Network Performance Analysis,” 2012.
- [55] S. Zander, T. Nguyen, and G. Armitage, “Automated traffic classification and

- application identification using machine learning,” *IEEE Conf. Local Comput. Networks 30th Anniv. (LCN’05)*, pp. 250–257, 2005.
- [56] M. Mirza, “A Machine Learning Approach To Problems in Computer Network Performance Analysis,” 2012.
- [57] V. F. Silva, D. F. Macedo, and J. L. Leoni, “Spectrum Decision in Wireless Sensor Networks Employing Machine Learning,” *2014 Brazilian Symp. Comput. Networks Distrib. Syst.*, pp. 386–393, 2014.
- [58] M. Muselli and I. N. Ricerche-geoa-italy, “A Machine Learning Approach to Estimate Frequency , Duration & Availability Indexes in Complex Networks,” pp. 250–255, 2005.
- [59] O. van den Biggelaar, J.-M. Dricot, P. De Doncker, and F. Horlin, “Power allocation in cognitive radio networks using distributed machine learning,” *2012 IEEE 23rd Int. Symp. Pers. Indoor Mob. Radio Commun. -*, pp. 826–831, 2012.
- [60] J. P. Cárdenas, G. Olivares, and R. Alfaro, “Automatic text classification using words networks [Clasificación automática de textos usando redes de palabras],” *Rev. Signos*, vol. 47, no. 86, pp. 346–364, 2014.
- [61] M. A. Alsheikh, S. Lin, D. Niyato, and H.-P. Tan, “Machine Learning in Wireless Sensor Networks: Algorithms, Strategies, and Applications,” no. c, pp. 1–24, 2014.
- [62] M. A. Gildardo, “Predicción de Tráfico en Redes de Telecomunicaciones basado en Técnicas de Inteligencia Analítica,” 2006.
- [63] H. Bhavsar and A. Ganatra, “A Comparative Study of Training Algorithms for Supervised Machine Learning,” *Int. J. Soft Comput. Eng.*, vol. 2, no. 4, pp. 74–81, 2012.
- [64] R. L. Rosa, “Predicting the Quality Level of a VoIP Communication through Intelligent Learning Techniques,” no. c, pp. 42–47, 2013.
- [65] A. Bashar, “Application of Bayesian Networks for Autonomic NGN Management,” 2011.
- [66] K. Muchammad and T. Ahmad, “Detecting Intrusion Using Recursive Clustering and Sum of Log Distance to Sub-centroid,” *Procedia Comput. Sci.*, vol. 72, pp. 446–452, 2015.
- [67] A. Bashar and G. Parr, “BARD: A novel application of Bayesian reasoning for proactive network management,” *10th Annu. ...*, 2009.
- [68] A. Bashar, “A Novel Distributed Call Admission Control,” pp. 871–881, 2011.
- [69] O. Tinoco Gómez, P. P. Rosales López, and J. Salas Bacalla, “Criterios de

selección de metodologías de desarrollo de software,” *Ind. Data*, vol. 13, no. 2, p. 70, 2014.

- [70] J. Plazas and J. Rojas “Detection of Risky Situations and Abnormal Events in Early Warning Platforms Based On Complex Event Processing” pp. 23-24,2015.
- [71] M. Antonio, R. Soria-vargas, M. A. Acevedo-mosqueda, J. Hernández-castillo, and M. Sánchez-meraz, “Sistema de video llamadas seguras empleando una PBX-Asterisk,” 2015.
- [72] F. Fokus, “Motivation for an Open Source IMS Core,” pp. 1–18, 2006.
- [73] "Ostinato Documentation" [En línea]. Disponible en: <https://ostinato.org/> [Accedido: 17-marzo-2016] .
- [74] "SipP Documentation" [En línea]. Disponible en: <http://sipp.sourceforge.net/doc/>. [Accedido: 17-marzo-2016] .
- [75] M. F. Borja, “Análisis de tráfico con Wireshark,” p. 52, 2011.
- [76] Q. Firehose, “User Guide,” no. October, pp. 1–19, 2017.
- [77] “Free AthTek NetWalk Home Edition _ AthTek.” [En línea]. Disponible en: <http://www.athtek.com/netwalk/free.html#.WmX0cVXiaHs>. [Accedido: 17-marzo-2016]
- [78] “Tasación por segundos y Saldos no Consumidos Documento Amarillo Centro de Conocimiento de la Industria Coordinador : Juan Pablo Hernández Líder : Gabriel Camilo Pérez Mayo de 2012,” 2012.
- [79] L. Arantón Areosa, “Web 2.0 y aplicaciones móviles (App),” *Enfermería Dermatológica*, vol. 6, no. 17, pp. 44–47, 2012.
- [80] J. F. Kurose and K. W. Ross, *Computer Networking A Top-Down Approach*, no. 5. 2013.
- [81] ITU-T, “G.114 One-way transmission time,” *Ser. G Transm. Syst. MEDIA, Digit. Syst. NETWORKS Int. Teleph. Connect. circuits – Gen. Recomm. Transm. Qual. an entire Int. Teleph. Connect.*, pp. 1–20, 2003.
- [82] S. Khalid, T. Khalil, and S. Nasreen, “A survey of feature selection and feature extraction techniques in machine learning,” *2014 Sci. Inf. Conf.*, pp. 372–378, 2014.
- [83] C. Wu, W. Qiu, Z. Zheng, X. Wang, and X. Yang, “QoS Prediction of Web Services Based on Two-Phase K-Means Clustering,” *2015 IEEE Int. Conf. Web Serv.*, pp. 161–168, 2015.
- [84] M. English, J. Buckley, and T. Cahill, “Fine-grained software metrics in practice,” *Proc. - 1st Int. Symp. Empir. Softw. Eng. Meas. ESEM 2007*, no. 1,

- pp. 295–304, 2007.
- [85] X. Chen, X. Liu, Z. Huang, and H. Sun, “RegionKNN: A scalable hybrid collaborative filtering algorithm for personalized web service recommendation,” *ICWS 2010 - 2010 IEEE 8th Int. Conf. Web Serv.*, pp. 9–16, 2010.
 - [86] “3 Diseño del modelo de aprendizaje,” pp. 43–51.
 - [87] A. Abdallah, M. A. Maarof, and A. Zainal, “Fraud detection system: A survey,” *J. Netw. Comput. Appl.*, vol. 68, pp. 90–113, 2016.
 - [88] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: Synthetic minority over-sampling technique,” *J. Artif. Intell. Res.*, vol. 16, pp. 321–357, 2002.
 - [89] “Manual CRISP-DM de IBM SPSS Modeler.”
 - [90] O. Rodríguez, “Metodología para el Desarrollo de Proyectos en Minería de Datos CRISP-DM,” p. 12.
 - [91] A. De Datos, C. Técnicas, D. E. A. D. E. Datos, and E. N. Weka, “Técnicas de uso de Weka,” *Knowl. Creat. Diffus. Util.*, pp. 1–55.
 - [92] J. Davis and M. Goadrich, “The relationship between Precision-Recall and ROC curves,” *Proc. 23rd Int. Conf. Mach. Learn. - ICML '06*, pp. 233–240, 2006.
 - [93] “Matriz de confusión.” [En línea]. Disponible en: <http://www.wikipedia.com> [Accedido: 25-Septiembre-2017]
 - [94] R. Madhu and R. Senthilkumar, “Recommendation System to Accomplish User Pursuit,” pp. 0–3, 2014.
 - [95] Q. Xu, S. S. Mohamed, M. M. a. Salama, M. Kamel, and K. Rizkalla, “Mass spectrometry-based proteomic pattern analysis for prostate cancer detection using neural networks with statistical significance test-based feature selection,” *2009 IEEE Toronto Int. Conf. Sci. Technol. Humanit.*, pp. 837–842, 2009.
 - [96] “Significacion estadística.” [En línea]. Disponible en: <http://www.wikipedia.com> [Accedido: 30-Septiembre-2017]
 - [97] R. R. Bouckaert and E. Frank, “Evaluating the Replicability of Significance Tests for Comparing Learning Algorithms,” *Adv. Knowl. Discov. data Min.*, pp. 3–12, 2004.
 - [98] X. Yang, H. He, D. Liu, and Y. Zhu, “Adaptive dynamic programming for robust neural control of unknown continuous-time non-linear systems,” *IET Control Theory Appl.*, vol. 11, no. 14, pp. 2307–2316, 2017.

- [99] R. R. Bouckaert *et al.*, “WEKA Manual for Version 3-7-12,” pp. 1–327, 2014.
- [100] D. J. Matich, “Redes Neuronales: Conceptos Básicos y Aplicaciones.,” *Historia Santiago.*, p. 55, 2001.
- [101] P. Cortez, “Multilayer Perceptron (MLP) Application Guidelines,” pp. 200–230, 2010.
- [102] M. D. E. Datos, “Weka,” pp. 1–23.
- [103] “masterofproject.” . [En línea]. Disponible en: <http://www.masterofproject.com> [Accedido: 28-Septiembre-2017]
- [104] “ibm.” [En línea]. Disponible en: <http://www.ibm.com> [Accedido: 17-October-2017]
- [105] I. Of and S. Cities, “ITU-T,” 2016.

Anexo A

En este anexo se presentan los resultados obtenidos realizando el mismo procedimiento de la sección 4.1.2 con el conjunto de datos de cuatro atributos.

Tabla A-1. Prueba de entrenamiento: Máquina de vector de soporte.

SVM	Entrenamiento			Prueba			Validación Cruzada(10)		
	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
% Entrenamiento									
10	4087	50	98,7914	36729	504	98,6464	18459	158	99,1513
20	8191	83	98,9969	32777	319	99,2361	16416	132	99,2023
30	12291	120	99,0331	28678	281	99,2297	14350	129	99,1091
40	16402	146	99,1177	24583	239	99,1371	12279	132	98,9364
50	20508	177	99,1443	20494	191	99,2766	10232	110	98,9364
60	24606	216	99,1298	16396	152	99,1815	8186	88	98,9364

Tabla A-2. Prueba de entrenamiento: Árbol de decisión.

DT/J48	Entrenamiento			Prueba			Validación Cruzada(10)		
	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
% Entrenamiento									
10	4136	1	99,9758	37217	16	99,957	18607	10	99,9463
20	8272	2	99,9758	33083	13	99,9607	16541	7	99,9577
30	12409	2	99,9839	28948	11	99,962	14471	8	99,9447
40	16546	2	99,9879	24811	11	99,9557	12401	10	99,9194
50	20682	3	99,985	20668	17	99,9178	10336	6	99,942
60	24816	6	99,9758	16537	11	99,9335	8272	2	99,9758

Tabla A-3. Prueba de entrenamiento: Red neuronal.

NN	Entrenamiento			Prueba			Validación Cruzada(10)		
% Entrenamiento	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
10	90	4137	0	100	37228	5	99,9866	18615	2
20	80	8274	0	100	33091	5	99,9849	16546	2
30	70	12411	0	100	28954	5	99,9827	14478	1
40	60	16548	0	100	28954	5	99,9827	12405	6
50	50	20684	1	99,9952	20681	4	99,9807	10339	3
60	40	24820	2	99,9919	24820	2	99,9919	8274	0

Tabla A-4. Prueba de entrenamiento: Redes bayesianas.

BN	Entrenamiento			Prueba			Validación Cruzada(10)		
% Entrenamiento	CC-T	CI-T	Precisión	CC-S	CI-S	Precisión	CC-V	CI-V	Precisión
10	4027	110	97,3411	36778	445	98,778	18397	220	98,8183
20	8147	127	98,4651	32690	406	98,7733	16346	202	98,7793
30	12222	189	98,4772	28602	357	98,7672	14293	186	98,7154
40	16341	207	98,7491	24518	304	98,7753	12238	173	98,6061
50	20446	239	98,8446	20438	247	98,8059	10212	130	98,743
60	24499	323	98,6987	16358	190	98,818	8177	97	98,8277