



**UNIVERSIDAD NACIONAL DE CHIMBORAZO
FACULTAD DE INGENIERÍA
CARRERA DE ELECTRÓNICA Y TELECOMUNICACIONES**

**DISEÑO DE UN MECANISMO DE GENERACIÓN DE
ACTUALIZACIONES DINÁMICO UTILIZANDO
APRENDIZAJE REFORZADO EN COMUNICACIONES IOT
CELULAR PARA OPTIMIZAR LA FRESCURA DE LA
INFORMACIÓN**

**Trabajo de Titulación para optar al título de:
Ingeniero en Electrónica y Telecomunicaciones**

Autor:

Casanova Rivera, Hugo Fernando

Tutor:

PhD. Luis Patricio Tello Oquendo.

Riobamba, Ecuador. 2022

DERECHOS DE AUTORÍA

Yo, **Hugo Fernando Casanova Rivera**, con cédula de ciudadanía **1804883583**, autor del trabajo de investigación titulado: **“DISEÑO DE UN MECANISMO DE GENERACIÓN DE ACTUALIZACIONES DINÁMICO UTILIZANDO APRENDIZAJE REFORZADO EN COMUNICACIONES IOT CELULAR PARA OPTIMIZAR LA FRESCURA DE LA INFORMACIÓN”**, certifico que la producción, ideas, opiniones, criterios, contenidos y conclusiones expuestas son de mi exclusiva responsabilidad.

Asimismo, cedo a la Universidad Nacional de Chimborazo, en forma no exclusiva, los derechos para su uso, comunicación pública, distribución, divulgación y/o reproducción total o parcial, por medio físico o digital; en esta cesión se entiende que el cesionario no podrá obtener beneficios económicos. La posible reclamación de terceros respecto de los derechos de autor (a) de la obra referida, será de mi entera responsabilidad; librando a la Universidad Nacional de Chimborazo de posibles obligaciones.

En Riobamba, 15 de noviembre de 2022.



Hugo Fernando Casanova Rivera

C.I: 1804883583

DICTAMEN FAVORABLE DEL TUTOR Y MIEMBROS DE TRIBUNAL;

Quienes suscribimos, catedráticos designados Tutor y Miembros del Tribunal de Grado para la evaluación del trabajo de investigación “**DISEÑO DE UN MECANISMO DE GENERACIÓN DE ACTUALIZACIONES DINÁMICO UTILIZANDO APRENDIZAJE REFORZADO EN COMUNICACIONES IOT CELULAR PARA OPTIMIZAR LA FRESCURA DE LA INFORMACIÓN**”, presentado por **Hugo Fernando Casanova Rivera**, con cédula de identidad número **1804883583**, certificamos que recomendamos la **APROBACIÓN** de este con fines de titulación. Previamente se ha asesorado durante el desarrollo, revisado y evaluado el trabajo de investigación escrito y escuchada la sustentación por parte de su autor; no teniendo más nada que observar.

De conformidad a la normativa aplicable firmamos, en Riobamba 15 de noviembre de 2022

MSc. Carlos Ramiro Peñafiel Ojeda
PRESIDENTE DEL TRIBUNAL DE GRADO



Dr. Klever Herman Torres Rodriguez
MIEMBRO DEL TRIBUNAL DE GRADO



PhD. Leonardo Fabián Rentería Bustamante
MIEMBRO DEL TRIBUNAL DE GRADO



PhD. Luis Patricio Tello Oquendo
TUTOR



CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL

Quienes suscribimos, catedráticos designados Miembros del Tribunal de Grado para la evaluación del trabajo de investigación **“DISEÑO DE UN MECANISMO DE GENERACIÓN DE ACTUALIZACIONES DINÁMICO UTILIZANDO APRENDIZAJE REFORZADO EN COMUNICACIONES IOT CELULAR PARA OPTIMIZAR LA FRESCURA DE LA INFORMACIÓN”**, presentado por **Hugo Fernando Casanova Rivera** con cédula de identidad número **1804883583**, bajo la tutoría de **PhD. Luis Patricio Tello Oquendo**; certificamos que recomendamos la **APROBACIÓN** de este con fines de titulación. Previamente se ha evaluado el trabajo de investigación y escuchada la sustentación por parte de su autor; no teniendo más nada que observar.

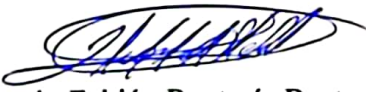
De conformidad a la normativa aplicable firmamos, en Riobamba 15 de noviembre de 2022



MSc. Carlos Ramiro Peñañiel Ojeda
MIEMBRO DEL TRIBUNAL DE GRADO



Dr. Klever Herman Torres Rodríguez
MIEMBRO DEL TRIBUNAL DE GRADO



PhD. Leonardo Fabián Rentería Bustamante
MIEMBRO DEL TRIBUNAL DE GRADO



CERTIFICACIÓN

Que, **Casanova Rivera Hugo Fernando** con CC: **1804883583**, estudiante de la Carrera **ELECTRÓNICA Y TELECOMUNICACIONES, NO VIGENTE**, Facultad de **INGENIERÍA**; ha trabajado bajo mi tutoría el trabajo de investigación titulado **"DISEÑO DE UN MECANISMO DE GENERACIÓN DE ACTUALIZACIONES DINÁMICO UTILIZANDO APRENDIZAJE REFORZADO EN COMUNICACIONES IOT CELULAR PARA OPTIMIZAR LA FRESCURA DE LA INFORMACIÓN"**, cumple con el **6 %**, de acuerdo al reporte del sistema Anti plagio **Urkund**, porcentaje aceptado de acuerdo a la reglamentación institucional, por consiguiente autorizo continuar con el proceso.

Riobamba, 10 de 11 de 2022

PhD. Luis Tello.
TUTOR(A) TRABAJO DE INVESTIGACIÓN

DEDICATORIA

"No soy adicto a vivir mirando para atrás, porque la vida siempre es porvenir y todos los días amanece".

José Mujica

Dedico este proyecto a Milton Sánchez. Puede que tu paso por el mundo fuera fugaz, pero me enseñaste que sin importar las adversidades que nos vaya presentando el destino, un hombre debe ser perseverante hasta el último día de su vida. A mis amados abuelos Martha y Chalo, por ser el pilar fundamental de mi formación personal, inculcando en mí a través del amor los valores que siempre me han guiado en cada una de mis decisiones. A mis padres Fernando y Gloria, por su cariño, paciencia, comprensión, pero sobre todo por demostrarme la gran fe que tienen en mí, sin todo su esfuerzo y trabajo incansable nada sería posible. A mi tía Katty, a quien quiero como una madre, por depositar toda su confianza en mí, demostrando que siempre podré contar con ella.

AGRADECIMIENTO

“Mucha gente pequeña, en lugares pequeños, haciendo pequeñas cosas, puede cambiar el mundo”.

Proverbio Africano

Quiero agradecer a cada una de las personas que de diferentes formas me acompañaron en este camino de buenos y malos momentos. Sin su apoyo desinteresado no hubiese sido posible la culminación de esta etapa de mi vida. Familia y Amigos, estas palabras son para ustedes. A todos mis docentes, especialmente a mi tutor PhD. Luis Patricio Tello O., por darme la oportunidad de ser partícipe de esta línea de investigación, compartiendo conmigo sus experiencias y conocimientos que me orientaron al correcto desarrollo y culminación exitosa del presente proyecto.

ÍNDICE GENERAL

CAPÍTULO I. INTRODUCCIÓN.....	15
1.1 Planteamiento del Problema	17
1.2 Objetivos.....	19
1.2.1 GENERAL	19
1.2.2 ESPECÍFICOS	19
CAPÍTULO II. MARCO TEÓRICO.....	20
2.1. Contextualización de los Sistemas IoT	20
2.1.1. Arquitectura de tecnologías IoT	21
2.1.2. Ventajas y desventajas de IoT	24
2.2. Análisis de inteligencia artificial aplicada a la IoT.....	25
2.3. IoT con tecnología Machine Learning.....	28
2.3.1. Machine learning en IoT.....	30
CAPÍTULO III. METODOLOGIA.....	32
3.1. Tipo de Investigación.....	32
3.2. Diseño de Investigación.....	32
3.3. Técnicas de recolección de Datos	32
3.3.1. La observación.....	32
3.3.2. Instrumentos de la investigación	33
3.4. Población de estudio y tamaño de muestra.....	33
3.4.1. Población	33
3.4.2. Muestra	33
3.5. Operacionalización de las variables.....	34
3.6.1. Machine Learning mediante Neural Fitting.....	36
3.6.2. Machine Learning mediante Q-Learning	38
3.7. Escenarios de estudio.....	41
3.7.1. Escenario 1	41

3.7.2. Escenario 2	42
3.7.3. Escenario 3	44
CAPÍTULO IV. RESULTADOS Y DISCUSIÓN	47
4.1. Resultados Escenario 1	47
4.2. Resultados Escenario 2	50
4.3. Resultados Escenario 3	52
4.4. Análisis estadístico de resultados	55
CAPÍTULO V. CONCLUSIONES y RECOMENDACIONES	65
ANEXOS	70

ÍNDICE DE TABLAS

Tabla 1. Operacionalización de las variables	34
Tabla 2 Valores de Escenario 1	41
Tabla 3 Valores obtenidos tráfico medio.....	42
Tabla 4 Valores de tráfico bajo.....	44
Tabla 5 Resumen datos escenarios sin control	55
Tabla 6 ANOVA de un factor.....	56
Tabla 7 ANOVA de un factor para análisis de Sig.....	56
Tabla 8 PRUEBA POST HOC en comparaciones múltiples.....	58
Tabla 9 POST HOC para Antigüedad de la Información.....	58
Tabla 10 Resumen datos escenarios controlados.....	59
Tabla 11 ANOVA de un factor.....	60
Tabla 12 ANOVA de un factor para análisis de Sig.....	60
Tabla 13 Estadísticos de grupo Escenario 1	61
Tabla 14 Prueba de muestras independientes	62
Tabla 15 Estadísticos de grupo Escenario 2	62
Tabla 16 Prueba de muestras independientes Escenario 2	63
Tabla 17 Estadísticos de grupo	64
Tabla 18 Prueba de muestras independientes Escenario 3	64

ÍNDICE DE FIGURAS

Figura 1. Integración de redes en IoT.....	21
Figura 2. Concepto de IoT.....	22
Figura 3. Red IoT con aprendizaje profundo.....	24
Figura 4. Reporte de dispositivos conectados a IoT mediante IA.....	28
Figura 5: Diagrama de bloque del modelo del sistema	35
Figura 6 Funcionamiento del algoritmo Bayessiano	37
Figura 7 Diagrama de funcionamiento Q-learning.....	39
Figura 8 Q-learning para sistema IoT.....	40
Figura 9 Código Q-learning para Escenario 1: Tráfico Alto.....	47
Figura 10 Resultados Ps Escenario 1: Tráfico Alto.....	48
Figura 11 Política de control Escenario 1: Tráfico Alto.....	48
Figura 12 Valor de la política Escenario 1	48
Figura 13 Recompensas en Escenario 1	49
Figura 14 Entrenamiento Escenario 1	49
Figura 15 Código Q-learning para Escenario 2: Tráfico Medio.....	50
Figura 16 Resultados Ps Escenario 2: Tráfico Medio	50
Figura 17 Política de control Escenario 2: Tráfico Medio	51
Figura 18 Valor de la política Escenario 3	51
Figura 19 Recompensas en Escenario 2	51
Figura 20 Entrenamiento Escenario 2	52
Figura 21 Código Q-learning para Escenario 3: Tráfico Bajo	52
Figura 22 Resultados Ps Escenario 3: Tráfico Bajo	53
Figura 23 Política de control Escenario 3: Tráfico Bajo	53
Figura 24 Valor de la política Escenario 3	53
Figura 25 Recompensas en Escenario 3	54
Figura 26 Entrenamiento Escenario 3	54
Figura 27 Antigüedad de la Información.....	55
Figura 28 Media Antigüedad de la Información	57
Figura 29 Diagrama Dispersión Antigüedad de la Información	59
Figura 30 Diagrama Dispersión Antigüedad de la Información	61

RESUMEN

El objetivo de este estudio fue diseñar un mecanismo dinámico para la generación de actualizaciones en comunicaciones celulares IoT utilizando aprendizaje reforzado para optimizar la métrica de la edad de la información. Se aplicó una metodología científica que nos permitió aplicar técnicas como el algoritmo de Bellman para cumplir con el control de la era de la información y así optimizar la comunicación de la red IoT y garantizar la entrega de la información a tiempo. El desarrollo se realizó en el software matemático MATLAB. Estudiamos tres escenarios para evaluar la carga máxima de tráfico soportada por la red; en cada uno de ellos, diseñamos el mecanismo para que la etapa de control sea directamente proporcional al AoI manteniendo el nivel de confiabilidad, en términos de probabilidad de acceso exitoso, superior al 97%. Los resultados fueron probados usando Neural Fitting para la predicción de valores, y la hipótesis alternativa fue aceptada a través de procesos estadísticos. Se recomienda continuar probando y modelando redes IoT utilizando tecnología de aprendizaje automático para una mayor precisión en estudios futuros.

Palabras claves: Actualizaciones, aprendizaje reforzado, antigüedad de la información, redes móviles, comunicaciones, Internet de las Cosas.

ABSTRACT

The present research work aimed to design “**A DYNAMIC EFFICIENT MECHANISM IN ORDER TO REPORT DATA UPDATES GENERATION IN CELLULAR IOT COMMUNICATIONS**” using reinforcement learning to optimize the age of performance metric information. A scientific methodology was applied, the same has allowed us to apply techniques such as Bellman's algorithm to fulfill with the control of the age of information and thus optimize the IoT network communication and guarantee on-time delivery information. The development was carried out in MATLAB mathematical software. Three scenarios have been studied to evaluate the maximum traffic load supported by the network; in each of them, the mechanism was designed, so that, the control proportional system directly to the AoI by keeping the reliability level, in terms of successful access probability ratio, greater than 97%. The results were tested using Neural Fitting for predicted value and the alternative hypothesis were accepted through statistical processes control. It is recommended continuing testing and modeling data networks using machine learning technology for greater accuracy future predictions.

Keywords: Updates, reinforced learning, age of performance information, mobile networks, communications, Internet devices.

DORIS ELIZABETH VALLE VINUEZA Firmado digitalmente por DORIS ELIZABETH VALLE VINUEZA
Fecha: 2022.11.15 09:29:55 -05'00'

Reviewed by: Mgs. Doris Valle V.

ENGLISH PROFESSOR

c.c 0602019697

CAPÍTULO I. INTRODUCCIÓN

En la actualidad, se evidencia que la tecnología está enfocada en gran parte al desarrollo de aplicaciones basadas en la conexión de dispositivos a través de internet. Frente a este tema, es indispensable hablar sobre la Internet de las Cosas (*Internet of Things*, IoT) que se refiere básicamente a la interconexión de un sistema de dispositivos que reciben y transmiten datos [1]. Una de las tecnologías habilitantes para IoT es la comunicación tipo máquina (*machine-type communications*, MTC).

Las MTCs se refieren a las comunicaciones automatizadas de datos entre dispositivos y la infraestructura de transporte de datos subyacente. Estas comunicaciones pueden ocurrir entre un dispositivo MTC y un servidor o directamente entre dos dispositivos MTC [2]. Este tipo de tecnología extiende su aplicación a una gran variedad de campos como la salud, logística, manufactura, automatización de procesos, energía y servicios públicos. El despliegue a gran escala de dispositivos basados en esta tecnología genera un desafío para la red, la cual debe enfrentar una mayor carga con posibles aumentos repentinos del tráfico de datos y proporcionar una comunicación eficiente y confiable.

La tecnología móvil ha tenido gran incidencia a lo largo del desarrollo corporativo. Desde sus inicios, con el Sistema Global de Comunicaciones Móviles (*Global System for Mobile*, GSM), se han desarrollado diversos servicios que permitieron mejorar las comunicaciones a nivel global, además de brindar soporte, no solo en el ámbito de las telecomunicaciones, sino fusionarlas con las diversas ramas científicas, sociales y hasta culturales del mundo entero. Por otra parte, la alta demanda de estos servicios ha permitido ir mejorando la tecnología móvil a fin de satisfacer las demandas de los usuarios, es así como se desarrolló la tecnología 3G, que evidenciaba una mejora considerable de velocidad en la transmisión de datos.

La red de telefonía celular LTE (*Long Term Evolution*) fue diseñada inicialmente para soportar comunicaciones humano a humano (*Human to Human*, H2H). Sin embargo, mediante el organismo de estandarización 3GPP (*3rd Generation Partnership Project*) se ha trabajado en diferentes características tales como ahorro de energía, ahorro de sobrecarga, reducción de señalización, reducción de complejidad y mejora de cobertura. Estas mejoras definen lo que es LTE-Advance, mediante la cual se intentó adaptar la red para soportar la alta demanda de servicios generada por equipos MTC [3].

Durante los últimos años, ha existido un consenso creciente de que los sistemas inalámbricos

5G admitirán tres servicios genéricos que, según la Unión Internacional de Radiocomunicaciones (UIT-R), se clasifican como banda ancha móvil mejorada (eMBB), comunicaciones masivas de tipo máquina (mMTC) y comunicaciones ultra fiables y de baja latencia (URLLC, también denominadas comunicaciones de misión crítica) [5]. En particular, un dispositivo mMTC está activo de forma intermitente y utiliza una velocidad de transmisión fija, normalmente baja, en el enlace ascendente. Se puede conectar una gran cantidad de dispositivos mMTC a una estación base (BS) determinada, pero en un momento dado solo un subconjunto desconocido (aleatorio) de ellos se activa e intenta enviar sus datos.

El estándar actual no está optimizado para el tráfico de comunicaciones masivas de tipo máquina (mMTC), debido a que se utiliza un protocolo de acceso aleatorio (*random access*, RA) al momento de conectarse a la red. En condiciones de tráfico elevado, se generará una situación de sobrecarga que afectará a la gestión eficiente de los recursos de red, esto puede ocasionar que no todas las actualizaciones enviadas por los diferentes dispositivos lleguen de manera oportuna y a tiempo. La información desactualizada puede conducir a estimaciones incorrectas del estado de un sistema particular, desperdicio de recursos y provocar una pérdida de rendimiento severa [4].

Para poder caracterizar de manera adecuada la puntualidad de las actualizaciones de estado en un sistema con mMTC, se estudiará una métrica de rendimiento que capta la frescura de la información recibida y es adecuada para aplicaciones que requieren información oportuna para realizar tareas específicas, por ejemplo, redes de sensores, sistemas ciber físicos, entre otras. Esta métrica de rendimiento se denomina antigüedad de la información (*Age of Information, AoI*) [7] y mide el tiempo en la comunicación entre dispositivos, desde la última generación de un paquete de actualización que se entregó hacia el destino. Esta métrica captura la frescura de la información desde la perspectiva del destino [8]. A diferencia de las métricas convencionales utilizadas en la ingeniería de tráfico en redes de datos, como el retardo o el throughput, AoI centraliza su funcionamiento en capturar de forma simultánea la latencia en la transmisión de actualizaciones y la velocidad a la que los paquetes se entregan entre dispositivos.

Debido al gran consumo de recursos de red en la tecnología IoT, los dispositivos conectados en esta red se enfrentan a dos problemas tecnológicos: i) La batería en los dispositivos, cuya capacidad de duración no ha avanzado en los últimos años, un claro ejemplo de ello son los

teléfonos móviles, en los cuales su carga es incapaz de aguantar más de un día de uso. ii) La conectividad y el continuo manejo de información, pues esto puede representar un problema en el tráfico de información, así como también, puede llegar hasta figurar como una brecha de seguridad.

Ante los desafíos presentados se plantea el diseño de un mecanismo para ajustar la tasa de generación de actualizaciones en escenarios de mMTC desde la perspectiva de AoI [9], en una red celular que cuenta con tráfico MTC y H2H de fondo. Esta investigación considera el entorno de una red de acceso celular y multitud de nodos que envían información a un único nodo que la procesa. Es importante destacar que, el mecanismo a diseñar se basará en técnicas de aprendizaje reforzado para dotar de autonomía a la red, al momento de gestionar el tráfico generado.

El aprendizaje reforzado es un área de la inteligencia artificial que está centrada en descubrir que acciones se debe tomar para maximizar la señal de recompensa; es decir, se centra en cómo mapear situaciones a acciones que se enfoquen en encontrar dicha recompensa. Al agente no se le dice que acciones tomar, sino al contrario, él debe experimentar para encontrar que acciones lo llevan a una mayor recompensa [11]. En el escenario de estudio se considerará como agente al nodo que envía actualizaciones de estado y como acciones de aumentar o disminuir el número de actualizaciones generadas de modo que la AoI se mantenga dentro de un rango óptimo (recompensa).

1.1 Planteamiento del Problema

MTC se ha convertido en uno de los habilitantes más representativos de IoT debido a que en su mayoría, este tipo de dispositivos son baratos con recursos de computación o energía limitados [2]. Dichos dispositivos representan un desafío para la red ya que esta debe enfrentarse a una mayor carga y posibles aumentos repentinos del tráfico MTC. Para ello, la red de telefonía celular ha desarrollado diversos estándares a fin de corregir estos inconvenientes, como es el caso del 3GPP, cuyo objetivo es adaptar la red a servicios de alta demanda. Por otra parte, la tendencia 5G repercutirá también en el consumo de recursos de un dispositivo. La solución consiste en crear dispositivos mucho más simples, utilizando tecnología de menor costo, que no consuma excesivos recursos y que sea capaz de transmitir datos.

Es en este contexto en el que firmas como Intel o Qualcomm [10] han pensado en

componentes de menor consumo energético y aptos para su integración en diferentes formas de objetos electrónicos, pues como se sabe, la tecnología IoT alberga dispositivos en diversos ámbitos como: domótica, sensores industriales, dispositivos para automóviles e inclusive en prendas de vestir. Esto genera un tráfico masivo de comunicación que son solicitudes masivas de acceso y de forma casi simultánea en un intervalo de tiempo corto. Este fenómeno se produce en el enlace ascendente del canal de comunicación celular que cuenta con un número limitado de recursos [10].

Los diversos dispositivos MTC que se conectan a una red IoT celular generan diferentes tipos de tráfico, la presencia de tráfico elevado produce sobrecarga y por ende una mala gestión de los recursos de red. Es aquí, donde surge un problema que ocasionaría que no todas las actualizaciones de los distintos dispositivos MTC lleguen de manera oportuna y a tiempo a la BS. Sin embargo, solo pocos estudios analizan el impacto de las comunicaciones masivas MTC desde la perspectiva de la métrica AoI en una red celular que cuenta con tráfico MTC y H2H.

Ante la problemática presentada y en base al análisis de la evaluación de distintos escenarios de mMTC desde la perspectiva de la AoI en un sistema de comunicación celular, se tiene como finalidad implementar un mecanismo adaptativo para la disminución de consumo de recursos en redes IoT, a través de una técnica de aprendizaje reforzado. Con esto se pretende que la red ajuste autónomamente la tasa de generación de actualizaciones en función de la carga de tráfico y de AoI con respecto a la gestión del tráfico generado para asegurar la llegada de todas las actualizaciones de los diferentes dispositivos MTC de manera oportuna y a tiempo.

En base a la problemática planteada el presente trabajo de investigación plantea la siguiente pregunta:

¿El ajuste dinámico de la tasa de generación de actualizaciones de los dispositivos MTC disminuye la AoI?

1.2 Objetivos

1.2.1 GENERAL

- Diseñar un mecanismo de generación de actualizaciones dinámico utilizando aprendizaje reforzado en comunicaciones IoT celular para optimizar la frescura de la información.

1.2.2 ESPECÍFICOS

- Evaluar distintos escenarios de mMTC desde la perspectiva de la AoI considerando un sistema de comunicación celular.
- Estudiar el efecto de dos patrones de generación de actualizaciones por parte de los usuarios MTC en la métrica AoI.
- Modelar el mecanismo adaptativo utilizando una técnica de aprendizaje reforzado para el ajuste de la tasa de generación de actualizaciones.
- Evaluar el rendimiento de la red integrando el mecanismo adaptativo en el patrón de generación de actualizaciones de los usuarios MTC en distintos escenarios desde la perspectiva de la AoI.

CAPÍTULO II. MARCO TEÓRICO

2.1.Contextualización de los Sistemas IoT

En la actualidad, el avance tecnológico ha producido un crecimiento exponencial en el uso del internet, esto ha generado un desafío para las industrias proveedoras de dicho servicio. La alta demanda de servicios y desarrollo tecnológico ha conseguido la aparición de nuevas tecnologías como servicio multimedia, video streaming. Sin embargo, los servicios no solo aplican al entretenimiento, en los últimos años con el desarrollo de la red 5G se ha ido produciendo un avance considerable en la telemedicina, y en las redes de nueva generación como es el caso de IoT.

IoT es la tecnología que permite la interconexión de dispositivos físicos, vehículos, edificios y otros elementos integrados con electrónica, software, sensores, actuadores y redes de conectividad que permiten a estos objetos recopilar e intercambiar datos para su posterior análisis. A diferencia del procesamiento y control de la señal digital tradicional que consumen demasiada potencia en los nodos y demasiado ancho de banda en la red al procesar series de tiempo periódicas, la tecnología IoT permite realizar muestreo por evento o muestreo aperiódico reduciendo así el consumo energético [12].

IoT lo cambiará todo, incluso a nosotros mismos. Si bien puede parecer una declaración arriesgada, hay que tener en cuenta el impacto que Internet ha tenido sobre la educación, la comunicación, las empresas, la ciencia, el gobierno y la humanidad. Claramente Internet es una de las creaciones más importantes y poderosas de toda la historia de la humanidad. Ahora debemos tener en cuenta que IoT representa la próxima evolución de Internet, que será un enorme salto en su capacidad para reunir, analizar y distribuir datos que podemos convertir en información, conocimiento y en última instancia, sabiduría. En este contexto, IoT se vuelve inmensamente importante [13].

Dicha tecnología introduce una nueva forma de calidad de vida a las personas, ofrece grandes facilidades para el usuario y su acceso a los datos o servicios específicos como educación, seguridad, asistencia médica o transporte. IoT permitirá el aumento de la productividad dentro de las empresas, gracias a su capacidad de integración de dispositivos inteligentes dentro de la red que incluso, pueden llegar a ser personalizados según la demanda o necesidad del cliente.

IoT trae beneficios de mejora de la gestión y el seguimiento de los activos y de los productos, aumenta la cantidad de datos de información y permite la optimización de equipos y uso de los recursos que puede traducirse en ahorro de costes. Además, ofrece la oportunidad de crear nuevos dispositivos interconectados inteligentes y explorar nuevos modelos de negocio [14].

IoT está compuesta por un conjunto disperso de diversas redes y varias aplicaciones, a medida que esta tecnología avanza se van integrando nuevos servicios a la misma, la inclusión de dichos servicios permitiría la potenciación de IoT.




Figura 1. Integración de redes en IoT

Fuente: [13]

2.1.1. Arquitectura de tecnologías IoT

IoT puede ser visto como una combinación de sensores y actuadores que son capaces de proporcionar y recibir información digitalizada y colocarla en redes bidireccionales capaces de transmitir todos los datos para ser utilizados por una gran cantidad de diferentes servicios y usuarios finales. Múltiples sensores pueden unirse a un objeto o dispositivo para medir una

amplia gama de variables físicas o fenómenos y luego transmitir todos los datos a la nube. La detección puede ser entendida como un modelo de servicio [13].




Figura 2. Concepto de IoT

Fuente: [13]

La estructura de los nuevos sistemas IoT están divididos en cuatro capas:

- a) Detección de objetos.
- b) Intercambio de datos.
- c) Integración de la información.
- d) Servicio de aplicaciones.

En IoT se agrega una capa de detección a los dispositivos que se conectan a la red, esto reduce los requisitos de capacidad de los equipos, lo que permite la interconexión entre ellos. Los sensores se comunican mediante la capa de integración de información, esta es la responsable de toda la comunicación, envío y recepción de paquetes a través de la red.

Por otra parte, el uso de las tecnologías en nube está creciendo de manera exponencial. Nuevas plataformas de infraestructuras y aplicaciones de software se ofrecen en el marco de la IoT. Algunas de las principales ventajas y beneficios de la IoT serán la creación de servicios innovadores con un mejor rendimiento y soluciones de valor añadido, junto con la reducción de los costos de adquisición de datos de los servicios existentes y la oportunidad de crear nuevas fuentes de ingresos en el contexto de un modelo de negocio sostenible. Estas aplicaciones se pueden orientar a los consumidores, negocios, comerciales, y actividades de

encuestas, a la comunidad industrial y científica mediante el aprovechamiento de los desarrolladores de aplicaciones [13].

Un sistema IoT cuenta con diversas tecnologías para su despliegue, entre las cuales se tiene:

- **RFID:** Tecnología de identificación automática sin contacto llamada *radio frequency identification* (identificación por radiofrecuencia). Con esta tecnología se puede lograr la identificación automática de objetos estáticos o dinámicos y de personas. La forma más básica del sistema RFID se compone de etiquetas, lectores y antenas. Este tipo de tecnología es útil para el IoT, porque con ella se logra la identificación de los diferentes objetos que interactúan en el IoT y se logra mayor facilidad para el manejo de la información [15].
- **Sensores:** Son una pieza clave para alcanzar al IoT, debido a que gracias a estos se logra la recopilación de información sobre el entorno en el que se encuentran los objetos. A partir de los avances en nanotecnología, se ha logrado que el tamaño de los microprocesadores sea cada vez menor sin que sufran pérdidas de velocidad de procesamiento [15].
- **Nanotecnología:** El estudio de partículas minúsculas se está utilizando para mejorar los productos alrededor de una serie de industrias, incluyendo los sectores de educación, medicina, energía y transporte. La utilización de nanotecnología hará posible que los objetos que interactúan y se conectan en la red unos con otros sean lo más pequeños posible. Se prevé que irán disminuyendo su tamaño con los avances en este campo [15].
- **Tecnologías inteligentes:** Las tecnologías inteligentes son los métodos empleados para lograr cierto propósito mediante el uso de un conocimiento a priori. Los objetos que obtienen inteligencia, después de la implantación de tecnologías inteligentes, se pueden comunicar con los usuarios activa o pasivamente. El contenido y la orientación de la investigación incluye principalmente: teoría de la inteligencia artificial, tecnologías avanzadas y sistemas de interacción entre humanos y máquinas, tecnologías y sistemas de control inteligente, procesamiento inteligente de señales, entre otras [15].



Figura 3. Red IoT con aprendizaje profundo

Fuente: [16]

2.1.2. Ventajas y desventajas de IoT

Dicha tecnología tuvo inicios a partir del año 2010, tiene por objetivo que, todo dispositivo de tipo electrónico se pueda conectar a Internet para el intercambio de información, el concepto inicial era M2M (máquina a máquina). Sin embargo, los altos costos y el crecimiento del internet con diversas tecnologías admitieron que IoT permita interacción con el ser humano y combine la inteligencia artificial, esto presenta las siguientes ventajas:

- **Facilidad de acceso a la información:** IoT nos proporciona datos valiosos sobre los dispositivos, lo que nos permitirá tomar decisiones más acertadas y de mayor éxito [17].
- **Mayor eficiencia y productividad:** Dado que los dispositivos pueden ser controlados a través de Internet, podemos ejecutar tareas de forma más cómoda, sencilla y eficiente, reduciendo los tiempos necesarios para realizar una acción con dicho dispositivo. Esto tendrá como consecuencia directa un incremento de nuestra productividad [17].

- **Ahorro de dinero:** IoT nos permite identificar cuando un dispositivo requiere de una reparación o cuando va a sufrir un deterioro importante, pudiendo actuar con anterioridad y evitar que se produzcan fallas en su infraestructura [17].
- **Automatización:** La inteligencia es una de las propiedades de IoT, que permite ejecutar tareas sin necesidad de la intervención humana mediante la automatización de procesos [17].

Así como la IoT tiene ventajas, también posee desventajas como:

- La información no se encuentra cifrada, por lo que no se nos ofrece una total seguridad [8].
- Puede llegar a haber falta de compatibilidad ya que IoT no está estandarizado, debido a que no se está llegando a trabajar del todo con el IEEE [8].
- Hay que saber qué información es fiable y cuál realmente es de valor [8].
- El software no es totalmente seguro y puede ser hackeado y el fin que suele tener no es nada bueno [8].

2.2. Análisis de inteligencia artificial aplicada a la IoT

Desde el inicio de los primeros ordenadores, surgía la inquietud por parte de los usuarios de si las computadoras tuvieran la oportunidad de aprender y convertirse en máquinas inteligentes, es así como esta interrogante fue denominada inteligencia artificial. Esta es la integración de diversas áreas como la matemática, la lógica y filosofía para la creación de diseño de sistemas y la resolución de problemas mediante la PC.

La inteligencia artificial (AI) se aplica en diversos ámbitos, en los cuales se registra la existencia de tareas repetitivas, alta precisión, manejo de grandes volúmenes de información, riesgo de vida, extrema complejidad en la resolución de problemas, entre otros.

La tendencia actual indica que las diferentes técnicas de AI tales como los algoritmos genéticos, las redes neuronales, la lógica difusa, las hiperheurísticas y en general los sistemas de aprendizaje automático (*Machine Learning*) han escalado hacia el ámbito de IoT [19].

La tendencia del IoT se ha orientado a ser cada vez más inteligente, es así como las empresas especializadas en el uso del IoT han combinado con la AI. Un ejemplo de esto, es el análisis basado en aprendizaje automático, el cual ayuda a la identificación de patrones y detección de anomalías que se genera en los sensores y dispositivos inteligentes. De acuerdo a los

estudios de la *International Data Corporation* (IDC), se menciona que a los próximos 5 años la AI será implementada directamente con los dispositivos IoT y de no ser el caso, esta tecnología tendría un avance limitado.

La AI es una de las ramas de las ciencias de la computación que más reconocimiento y popularidad ha suscitado en años recientes, puesto que supone un emocionante campo con mucho potencial por explorar y aplicar. La IA no es un término fácil de definir. Las implicaciones de la palabra inteligencia dificultan enormemente un consenso entre la comunidad para aceptar una única definición. Así, se pueden tener en cuenta cuatro puntos de vista a la hora de enfocar la IoT [20].

El primer enfoque está basado en el comportamiento humano, este considera que una máquina debe tener características similares a las del ser humano. El desarrollo se basa en la prueba de Turing, el cual si fuera superado por una máquina significaría que esta tiene el comportamiento similar al de una persona. Por otra parte, hay científicos que consideran que dicho comportamiento inteligente no sería más que una simulación del pensamiento.

El segundo enfoque del comportamiento humano pone en manifiesto las capacidades que debe tener la máquina las cuales son: procesamiento de lenguaje natural, representación del conocimiento, razonamiento automatizado y aprendizaje automático. Dicho modelo es evaluado por el test total de Turing desarrollado por Harnad, este propone que la evaluación se base en los estímulos externos incluido las habilidades de percepción y manipulación de objetos a través de la visión dentro de un ordenador.

El tercer enfoque está considerado desde el punto de vista cognitivo humano, establece que la máquina debería pensar como lo hace el ser humano. Sin embargo, al no existir una teoría concreta sobre la mente, dicho enfoque se vuelve un poco surrealista, y puede tener ciertos fallos en la interpretación.

El último enfoque se conoce como el de la actuación racional, mediante el uso de agentes racionales o inteligentes. Un agente racional es aquel agente computacional que busca obtener el mejor resultado de actuación teniendo en cuenta las percepciones recibidas de su entorno, capaz de operar de forma autónoma y de adaptarse a los cambios. Parte del comportamiento de estos agentes vienen determinados por la lógica, comentada en el enfoque del pensamiento racional [20].

La AI, es una tendencia que aumenta de manera significativa el valor de las implementaciones que se realizan de IoT, debido a que ofrece a los dispositivos y sensores la capacidad de predecir posibles escenarios futuros para que puedan tomar decisiones basadas en un análisis de información recolectada. Un claro ejemplo de esto son los autos conectados del fabricante de coches y motos premium BMW, los cuales pueden acceder a los datos compartidos por los propietarios de los demás vehículos y a las capacidades de AI de IBM *Watson Internet of Things*, a través de la plataforma *CarData* de BMW [21].

Uno de los pioneros en IoT con la integración de AI es AWS, quienes han identificado ciertos principios fundamentales para un entorno combinado, estos son:

- **Agilidad:** Libertad de analizar, ejecutar y crear negocio rápidamente y las iniciativas técnicas sin restricciones.
- **Escala:** Ampliar la infraestructura a nivel regional o global para cumplir sin problemas.
- **Costo:** Comprender y controlar los costos de operar una plataforma de IoT.
- **Seguridad:** Comunicación segura desde el dispositivo a través de la nube.

Se asegura que una empresa que selecciona una plataforma que tiene estas libertades y promueve estos principios mejorará el enfoque organizativo en los diferenciadores de su negocio y el valor estratégico de implementar soluciones dentro de IoT [20].

Con el crecimiento de IoT, se ha tenido un crecimiento exponencial en la industria tecnológica, estas empresas han iniciado una planificación e implementación de sensores con IA para que la red del IoT pueda analizar los datos de los dispositivos, esto ayuda a la automatización de operaciones en tiempo real, para una mejor interacción con sus clientes. La expansión y el desarrollo tecnológico ha incrementado en diversos campos como, transporte, salud, hogar, industria y seguridad. En la Figura 4 se evidencia el crecimiento que ha tenido esta tecnología.




Figura 4. Reporte de dispositivos conectados a IoT mediante IA.

Fuente: [21]

2.3. IoT con tecnología Machine Learning

El *machine learning* también conocido como aprendizaje automático, es una metodología de automatización de construcción de modelos analíticos, se deriva de la AI y se basa en que los sistemas pueden aprender datos a través de la identificación de patrones para la toma de decisiones con la mínima intervención humana.

El aprendizaje automático, comúnmente abreviado como ML, es un tipo de AI que 'aprende' o se adapta con el tiempo. En lugar de seguir reglas estáticas codificadas en un programa, esta tecnología identifica patrones de entrada y contiene algoritmos que evolucionan con el tiempo [22].

ML es una forma de la AI que permite a un sistema aprender de los datos en lugar de aprender mediante la programación explícita. Sin embargo, *ML* no es un proceso sencillo. Conforme el algoritmo ingiere datos de entrenamiento, es posible producir modelos más precisos basados en datos. Un modelo de *ML* es la salida de información que se genera cuando entrena su algoritmo de *ML* con datos. Después del entrenamiento, al proporcionar un modelo con una entrada, se le dará una salida [23].

ML hace referencia al campo especializado en el reconocimiento de patrones complejos de datos, este se diferencia de la programación clásica, que se ejecuta una y otra vez la misma

operación, por el contrario, ML busca que sus programas obtengan la información de forma autónoma y los analicen para una posterior automatización.

Las técnicas empleadas en ML son para la mejora de la precisión de los modelos predictivos, estos dependen de la naturaleza del problema industrial o de los que el cliente tenga, se basa en diferentes enfoques, mismos que se fundan en el tipo y volumen de datos, de acuerdo con IBM las categorías de *ML* son:

Aprendizaje supervisado: El aprendizaje supervisado comienza típicamente con un conjunto establecido de datos y una cierta comprensión de cómo se clasifican estos datos. El aprendizaje supervisado tiene la intención de encontrar patrones en datos que se pueden aplicar a un proceso de analítica. Estos datos tienen características etiquetadas que definen el significado de los datos. Por ejemplo, se puede crear una aplicación de ML con base en imágenes y descripciones escritas que distinga entre millones de animales [23].

Aprendizaje no supervisado: El aprendizaje no supervisado se utiliza cuando el problema requiere una cantidad masiva de datos sin etiquetar. Por ejemplo, las aplicaciones de redes sociales, tales como *Twitter*, *Instagram* y *Snapchat*, tienen grandes cantidades de datos sin etiquetar. La comprensión del significado detrás de estos datos requiere algoritmos que clasifican los datos con base en los patrones o clústeres que encuentra. El aprendizaje no supervisado lleva a cabo un proceso iterativo, analizando los datos sin intervención humana. Se utiliza con la tecnología de detección de *spam* en *e-mails*. Existen demasiadas variables en los *e-mails* legítimos y de *spam* para que un analista etiquete una cantidad masiva de *e-mail* no solicitado. En su lugar, los clasificadores de *ML*, basados en *clustering* y asociación, se aplican para identificar *e-mail* no deseado [23].

Aprendizaje por refuerzo: El aprendizaje por refuerzo es un modelo de aprendizaje conductual. El algoritmo recibe retroalimentación del análisis de datos, conduciendo el usuario hacia el mejor resultado. El aprendizaje por refuerzo difiere de otros tipos de aprendizaje supervisado, porque el sistema no está entrenado con el conjunto de datos de ejemplo. Más bien, el sistema aprende a través de la prueba y el error. Por lo tanto, una secuencia de decisiones exitosas conduce al fortalecimiento del proceso, porque es el que resuelve el problema de manera más efectiva [23].

Deep learning: El *deep learning* es un método específico de *ML* que incorpora las redes neuronales en capas sucesivas para aprender de los datos de manera iterativa. El *deep*

learning es especialmente útil cuando se trata de aprender patrones de datos no estructurados. Las redes neuronales complejas de *deep learning* están diseñadas para emular cómo funciona el cerebro humano, así que las computadoras pueden ser entrenadas para lidiar con abstracciones y problemas mal definidos. Las redes neuronales y el *deep learning* se utilizan a menudo en el reconocimiento de imágenes, voz y aplicaciones de visión por computadora [23].

2.3.1. Machine learning en IoT

En la actualidad, existen diversos dispositivos que producen datos en tiempo real los cuales son enviados hacia un servidor; este principio es parte del concepto del IoT. A su vez que, la información ha sido almacenada, esta puede ser procesada para diseñar un modelo de ML para encontrar patrones de información.

ML junto con IoT son componentes esenciales de las ciudades inteligentes. El concepto de ciudad inteligente consiste en aplicar tecnologías y análisis de datos para optimizar servicios en distintas áreas, como lo son la comunicación, la economía, agricultura, servicios públicos, entre otros, con el objetivo de mejorar el estilo de vida de las personas [24].

IoT en conjunto con *ML* tiene un gran aporte para la industria e instituciones que busquen automatizar procesos a fin de disminuir carga laboral innecesaria. Con el avance tecnológico se busca mejorar la calidad de vida, es así como, el aprendizaje automático ofrece el mejor rendimiento a la hora de procesar y analizar grandes volúmenes de datos de alta dimensión, lo que lo convierte en particularmente útil e interesante en la IoT debido al gran número de dispositivos que recogen y comparten datos no homogéneos. Tras pasar por un proceso de análisis estadístico, esos datos son un tesoro para el desarrollo de nuevas aplicaciones inteligentes [25].

El aprendizaje automático utiliza experiencias anteriores para identificar patrones y construir modelos que ayuden a predecir eventos futuros y a tomar mejores decisiones. El aprendizaje automático se ocupa principalmente de la precisión y la eficacia de un sistema y ayuda a eliminar los errores humanos, además permite que los datos generen ideas y facilita que el IoT alcance su óptima utilidad. Millones de dispositivos interconectados están generando enormes volúmenes de datos con el IoT y el aprendizaje automático usa estos datos, proporciona tendencias futuras, detecta anomalías y sustituye los procesos manuales, por la automatización en los procedimientos críticos.

En una red IoT podemos reconocer tres capas diferentes. Cada uno de ellas se caracteriza por la disponibilidad de diferentes recursos y datos, donde el aprendizaje automático es aplicable: Dispositivos IoT, dispositivos de borde y la nube. Con la llegada de las nuevas tecnologías, es posible integrar el uso de redes neuronales y técnicas de aprendizaje automático en todos los niveles del IoT para realizar análisis de datos complejos a nivel local. Los dispositivos IoT, como los sensores típicamente limitados, pueden procesar localmente los datos sin enviarlos por la red, reduciendo la latencia y evitando problemas de seguridad. Al trasladarse a la nube, es posible realizar análisis más complejos gracias a la mayor potencia de cálculo y al aprovechamiento de los datos procedentes de distintas fuentes, lo que abre el mundo de la IoT a casos de uso nuevos y muy innovadores [25].

Se prevé que para el año 2025 existirá más de 60.000 millones de dispositivos adaptados a la tecnología IoT, estos almacenarán información en plataformas con la nube como *IoT Edge*, *Microsoft Azure*, *Amazon AWS*. Por tal razón es importante integrar *ML* a la nueva tendencia, esto permitirá a las empresas aumentar su eficiencia y reducir costos mediante la automatización de procesos gracias a los datos recabados en los sensores. Sin embargo, es importante resaltar que, toda la infraestructura deberá tener una adecuada gestión de datos, así como también una correcta estrategia analítica.

Para analizar los datos recogidos y extraer información significativa y crear aplicaciones inteligentes, es necesaria la intervención humana. Los dispositivos de la IoT no sólo tienen que recoger datos y comunicarse con otros dispositivos, sino también ser autónomos. Tienen que ser capaces de tomar decisiones basadas en el contexto y aprender de los datos recogidos. Esta necesidad llevó a la creación del término "IoT cognitivo". Además, existe la necesidad de contar con dispositivos IoT inteligentes, capaces de crear aplicaciones inteligentes automatizadas con asignación de recursos, comunicación y funcionamiento de la red. El despliegue de algoritmos de ML en una infraestructura de IoT puede introducir mejoras significativas en las aplicaciones o en la propia infraestructura. El ML puede aplicarse para optimizar la red, evitar la congestión y optimizar la asignación de recursos, pero también para el análisis de datos en tiempo real o fuera de línea y la toma de decisiones [26].

CAPÍTULO III. METODOLOGIA.

3.1. Tipo de Investigación

El tipo de investigación de este proyecto es cuantitativa, debido a que las variables pueden ser sometidas a medición. Es decir, emplea procedimientos cuantitativos y estadísticos para recoger información y procesarla; emplea procedimientos hipotético-deductivos [27]. Por lo tanto, se pretende verificar que los resultados en la configuración dinámica a través de la implementación de aprendizaje reforzado mejorarán el comportamiento de la métrica AoI en diversos escenarios en los que se varía el número de dispositivos en la red.

3.2. Diseño de Investigación

El diseño del presente estudio es experimental donde, los datos se obtienen por observación de hechos condicionados por el investigador, en donde se manipula una sola variable y se espera la respuesta de otra variable [28].

El uso del método experimental nos ayuda a realizar pruebas en diversos escenarios para el análisis del funcionamiento de ML dentro de los sistemas IoT; de esta forma se podrá obtener resultados aproximados con un mínimo porcentaje de error en el momento de establecer el control de actualizaciones en la red.

3.3. Técnicas de recolección de Datos

3.3.1. La observación

La observación es una técnica de investigación que consiste en observar personas, fenómenos, hechos, casos, objetos, acciones, situaciones, con el fin de obtener determinada información necesaria para una investigación [29]. Se fundamenta en la unión de normas orientadas a evaluar un fenómeno específico para dar a comprender la realidad de este y poder analizar de forma sistemática y con escrupulosidad, cualquier situación que se dé con respecto a los objetivos proyectados en la investigación.

En este caso, la parte primordial a estudiar es la métrica AoI. Para medir la misma necesitamos tener en cuenta los distintos paquetes de actualización que los dispositivos generan y transmiten. Cada dispositivo cuenta con una marca de tiempo e identificación (ID) que permite a la estación base registrar la métrica AoI contenida en el paquete y a qué usuario

pertenece dicha información, generando así diferentes parámetros que se debe considerar y son los siguientes: Tiempo de generación (Generation Time), tiempo de llegada (Arrivals Time), número de transmisiones de preámbulo (Num. Preamble Tx), identificativo por usuario (ID) y finalmente el tiempo desde su generación hasta su recepción por la estación base medido en milisegundos (AoI).

3.3.2. Instrumentos de la investigación

Para el desarrollo del presente documento se utilizarán los siguientes instrumentos:

- 3GPP TS 36.211 Especificación sobre los Canales Físicos y Modulación.
- 3GPP TR 37.868 Estudio sobre mejoras en el RAN para MTC.
- 3GPP TS 36.321 Especificación del protocolo de Control de Acceso al Medio
- Artículos Científicos relacionados con *ML* como mecanismo adaptativo de tráfico masivo.
- Artículos Científicos relacionados con la métrica AoI en escenarios de mMTC.
- Software Matlab para implementar el modelo de simulación

3.4. Población de estudio y tamaño de muestra

3.4.1. Población

La población correspondió a las mediciones de la métrica AoI de todos los dispositivos que tuvieron comunicación exitosa dentro de la red IoT. El valor máximo que se puede obtener es de $N= 144$ mediciones.

3.4.2. Muestra

Mediante el muestreo aleatorio simple se calculó el tamaño de la muestra, considerando que la población es finita, es decir $N= 140$ mediciones de la métrica AoI. Para ello se utilizó la siguiente ecuación:

$$n = \frac{N * Z_a^2 * p * q}{e^2 + (N - 1) + Z_a^2 * p * q}$$

Sabiendo de antemano que n es igual al tamaño de la muestra buscado, N el tamaño de la población, Z parámetro estadístico que depende del nivel de confianza; en su mayoría, el nivel de confianza suele ser del 95% (α), entonces, $Z=1.96$. El dato de estimación p si no

se obtiene de estudios anteriores, se considera que la condición la cumplan un 50% y, por tanto, que no la cumplan q el otro 50%; $e=0.01$ es el margen de error.

Por lo tanto, la muestra corresponderá a $n = 140$ mediciones de la métrica AoI.

3.5. Operacionalización de las variables

- **Variable dependiente**
 - Antigüedad de la Información (AoI).
- **Variable independiente**
 - Número de actualizaciones generadas por los usuarios MTC (U).

Tabla 1. Operacionalización de las variables

Variable Independiente	Concepto	Indicadores	Instrumento
Número de actualizaciones de los usuarios MTC (U).	Se define como el tráfico generado, dicho tráfico está representado por el número de actualizaciones por segundo que cada usuario MTC carga a la red.	- Número de dispositivos en la red -Número de transmisiones generadas por los dispositivos.	Observación directa a través de un modelo de simulación del canal de acceso aleatorio en LTE-A y un bloque de control de actualizaciones para captar la información fresca generada por los dispositivos MTC sometidos a distintos escenarios con diferentes patrones de generación de actualizaciones.
Variable Dependiente	Concepto	Indicadores	
Antigüedad de la información (AoI)	Se define como la nueva métrica que captura la frecuencia sobre actualizaciones de conocimiento que un sistema tiene sobre un proceso observado de forma remota, es decir	-Tiempo de generación. -Tiempo de llegada. - Probabilidad de acceso satisfactorio	

	captura conjuntamente la latencia en la transmisión de actualizaciones y la velocidad a la que se entregan.		
--	---	--	--

Fuente: Autor

Además de las variables dependientes y para un mejor entendimiento se ha utilizado como modelo de referencia el diagrama de bloques que se presenta en la Figura 5.

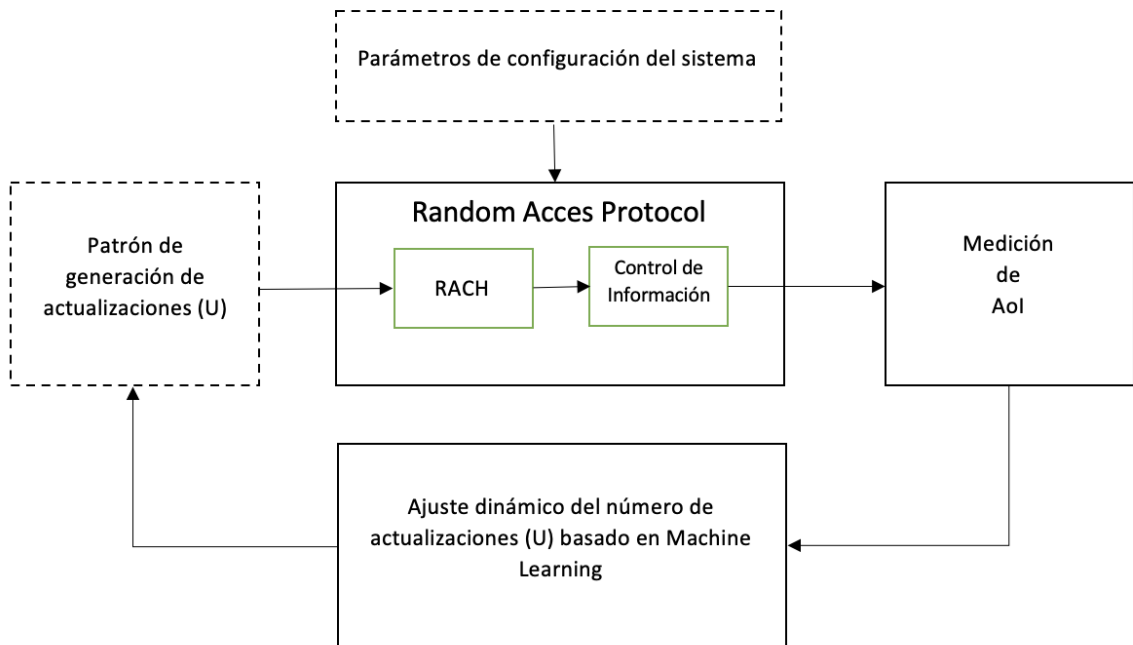


Figura 5: Diagrama de bloque del modelo del sistema

Fuente: Autor

En donde cada una de las funciones de los bloques se detalla a continuación:

- Parámetros de Configuración del sistema:** Se configurarán los parámetros del sistema para realizar las debidas pruebas dentro del modelo de simulación de la red en Matlab.

- **Patrón de generación de actualizaciones (U):** Se modelan dos patrones de generación de actualizaciones para dispositivos sincronizados y no sincronizados.
- **RACH:** Este bloque implementa el intercambio de mensajes que se producen en el canal de acceso aleatorio de la estación base que interfiere en la transferencia de información
- **Control de Información:** Este bloque permitirá descartar información obsoleta en la red considerando las nuevas actualizaciones generadas.
- **Resultados AoI:** Una vez analizados los datos, se procede a presentar los resultados referentes a las actualizaciones, estos serán enviados al bloque de aprendizaje reforzado para ajustar el número de actualizaciones que generarán los dispositivos.
- **Ajuste dinámico del número de actualizaciones (U) basado en Machine Learning:** Función encargada de implementar el algoritmo de aprendizaje reforzado, operación que permitirá la reducción del consumo de recursos en la red.

3.6. Métodos de análisis y procesamiento de datos

Para el análisis y procesamiento de datos se utilizaron dos métodos establecidos por Matlab que constan de diversos procesos como:

- Aplicaciones de tipo punto y clic para el entrenamiento y comparación de modelos.
- Procesamiento avanzado de señales y comparación de modelos
- Programación automática para el ML
- Algoritmos de clasificación, regresión y agrupación para manejo de aprendizaje supervisado y no supervisado
- Ejecución más rápida que con código abierto en la mayoría de los cálculos estadísticos y de ML

3.6.1. Machine Learning mediante Neural Fitting

La aplicación Neural Net Fitting permite crear, visualizar y entrenar una red de predicción de valores de dos capas para resolver problemas de ajuste de datos. Con esta aplicación, el usuario puede:

- Importar datos desde un archivo o base de datos externa o utilizar el espacio de trabajo de MATLAB.
- Dividir los datos en conjuntos para entrenamiento, validación y prueba.

- Definir y entrenar una red neuronal para la predicción de datos.
- Evaluar el rendimiento de la red mediante el error cuadrático medio y el análisis de regresión.
- Analizar los resultados mediante gráficos de visualización, como el ajuste de regresión o el histograma de errores.
- Permite generar de scripts de código .m para la visualización de los resultados y así personalizar el proceso de formación.

La aplicación Neural Fitting posee tres algoritmos para el análisis y procesamiento de la información. Los algoritmos de aprendizaje supervisado son capaces de clasificar los datos. Los algoritmos de aprendizaje sin supervisión permiten agrupar los datos. Existe un tipo de algoritmo el cual se basa en la probabilidad condicional. Es decir, al analizar cómo una variable afecta a la probabilidad de que suceda otra variable. El algoritmo más conocido para este tipo de análisis es el algoritmo bayesiano, este se sustenta en la teoría de la estadística de Bayes. Es uno de los algoritmos de clasificación del aprendizaje de máquinas. Comúnmente es utilizado principalmente para la clasificación binaria o multiclase.

El algoritmo de Bayes brinda un enfoque probabilístico de la inferencia, se basa en asumir que las incógnitas de interés siguen distribuciones probabilísticas. Este nos permite conseguir soluciones óptimas de valores mediante las distribuciones y los datos observados, además brinda la posibilidad de realizar una ponderación probabilidad de ocurrencia de una hipótesis mediante un análisis cuantitativo.




Figura 6 Funcionamiento del algoritmo Bayesiano

Fuente: [22]

Dentro de los bloques de entrada se tiene:

- Functions points: Es el recuento de puntos o datos de la función para un proyecto concreto.
- F.P. standard: Este campo especifica qué estándar de puntos de función se utilizó, por ejemplo, CPM 4.0 IFPUG 4, IFPUF4.1, entre otros.
- Language: Define el tipo de lenguaje utilizado para el proyecto, por ejemplo, 3GL, 4GL, generador de aplicaciones, entre otros.
- Lines of code: El número de líneas de código fuente (SLOC) producidas por el proyecto.

A través de un estudio experimental se utiliza el Neural Fitting para estimar las líneas de código y la predicción del AoI del proyecto, una vez que se conoce el número de actualizaciones del sistema IoT. El entrenamiento de la red neural se basa en los datos obtenidos para predicciones futuras, es así que mientras mayor sea la cantidad de información recolectada se podrá obtener valores más aproximados a los tiempos de actualización y AoI.

3.6.2. Machine Learning mediante Q-Learning

El algoritmo Q-learning es un método de aprendizaje por refuerzo sin modelo, en línea y fuera de la política. Un agente de Q-learning es un agente de aprendizaje por refuerzo basado en valores que entrena a un crítico para estimar el retorno o las recompensas futuras. Para una observación dada, el agente selecciona y genera la acción para la cual el rendimiento estimado es mayor.

A diferencia de neural fitting, el aprendizaje reforzado Q-Learning no requiere un conjunto de datos estáticos, este opera en un entorno dinámico y profundiza su análisis de las experiencias recopiladas. Los datos, también conocidos como experiencias son recopiladas durante el entrenamiento mediante interacciones de prueba y error entre el entorno y un agente de software. Este aspecto es importante, puesto que dicha técnica no necesita recopilar, preprocesar y etiquetar datos previos al entrenamiento.

Dicho de otro modo, mediante el incentivo adecuado, un modelo de aprendizaje reforzado puede comenzar a aprender un comportamiento por sí solo y sin supervisión.

A continuación, se muestra el modelo de aprendizaje reforzado presentado por Matlab:




Figura 7 Diagrama de funcionamiento Q-learning

Fuente: [23]

Donde:

- La política es un mapeo que selecciona acciones basadas en las observaciones del entorno. Por lo general, la política es un aproximador de funciones con parámetros ajustables, como una red neuronal profunda.
- El algoritmo de aprendizaje actualiza continuamente los parámetros de la política en función de las acciones, las observaciones y la recompensa. El objetivo del algoritmo de aprendizaje es encontrar una política óptima que maximice la recompensa acumulada recibida durante la tarea.

El aprendizaje reforzado Q-Learning está sustentado mediante el algoritmo de Bellman que se define mediante la fórmula:

$$Q(s, a) = r + \gamma \max_{a'} Q(s', a')$$

Para la resolución de la ecuación de Bellman el valor Q del estado de s y la acción a [$Q(s,a)$] debe ser equivalente a la recompensa r que se obtiene posterior a la ejecución, más el valor Q de ejecutar la mejor acción posible a' desde el próximo estado s' ; el cual se multiplica por

un factor de descuento conocido como γ (discount factor), este valor posee un rango $\gamma \in (0, 1]$. El parámetro γ se usa para decidir cuál será el peso de las recompensas a corto y a largo plazo.

El Algoritmo de Bellman para Q-learning actúa de la siguiente forma:

- El agente recibe un estado s , y una recompensa r
- El agente escoge una acción a del conjunto de acciones disponibles y la envía al entorno
- El entorno ejecuta la acción a y su estado pasa, entonces a $s+1$
- El intérprete recibe, entonces una observación $o+1$, interpreta el nuevo estado $s+1$ y calcula la recompensa $rt+1$ correspondiente a la transición $(s; a; s+1)$

Es importante mencionar que, de acuerdo con la política se determina la acción a realizar, basándose en el estado en el que se ve el entorno. Además, este presenta como un mapeado de estados a acciones, los cuales brindan la probabilidad para que el agente tome una acción determinada cuando el entorno se encuentra en un estado determinado. Al final el agente debe aprender cuál es la política y así obtener la mayor recompensa. En el estudio la implementación de Q-learning se realiza como se ilustra en el Diagrama de la Figura 8.

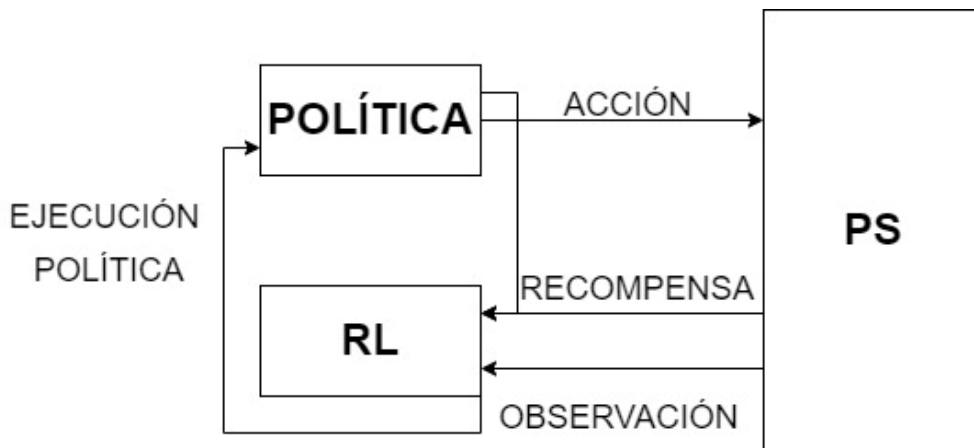


Figura 8 Q-learning para sistema IoT

Fuente: Autor

Donde:

- **POLÍTICA:** Establece los valores AoI, U, Ps para el entorno, en el cual Ps debe ser mayor o igual a 0.97.

- **REINFORCEMENT LEARNING (RL):** Bloque de procesamiento mediante el algoritmo de Bellman, para controlar que el valor Ps sea el adecuado.

3.7. Escenarios de estudio

El presente trabajo está sustentado a partir de [1]. Para las pruebas a realizarse se establecen 3 escenarios y se analizará la carga el tráfico considerando el número de usuarios del sistema IoT. Los escenarios se han clasificado por:

- **Escenario 1:** Tráfico alto, 140 usuarios conectados a la red
- **Escenario 2:** Tráfico medio, 70 usuarios conectados a la red
- **Escenario 3:** Tráfico bajo, 35 usuarios conectados a la red

En cada escenario se analizarán los siguientes parámetros:

- NumEs= Número de Usuarios
- Update= Número de actualizaciones
- T-Mean= Valor equivalente al promedio de AoI
- Ps= Probabilidad de accesos satisfactorio

3.7.1. Escenario 1

El escenario 1 está considerado la obtención del tráfico mediante las actualizaciones generadas por 140 usuarios los cuales podrán enviar hasta 72 actualizaciones al momento, posterior al proceso realizado se evidencia los resultados de PS y T-Mean para el posterior análisis y control de las actualizaciones, los resultados se muestran a continuación:

Tabla 2 Valores de Escenario 1

NumEs	Udpate	Tmean	Ps
140	1	555,94399	1
140	2	306,206792	1
140	3	223,092887	1
140	4	181,196009	1
140	5	156,079421	1

140	6	139,596699	1
140	7	127,550904	1
140	8	118,66331	0,99997024
140	9	111,816156	0,99996032
140	10	106,994236	0,99992857
140	11	103,063562	0,99985931
140	12	100,711444	0,9996627
140	13	99,7445098	0,99909341
140	14	100,730107	0,99792517
140	15	103,23241	0,99474603
140	16	110,78762	0,9813244
140	17	122,89253	0,94107143
140	18	132,897225	0,88603175
140	19	139,856137	0,83003759

Fuente: Autor

Se puede observar que a partir de 16 actualizaciones empieza aumentar el tiempo promedio, así como el valor Ps llega al límite de tolerancia para la generación de las actualizaciones, es decir, el control del sistema (valor máximo de actualizaciones que puede generar cada usuario) debe ser aplicado a partir de las 16 updates para 140 usuarios.

3.7.2. Escenario 2

El escenario dos está conformadas por 70 usuarios los cuales envían información de hasta 72 actualizaciones al mismo tiempo, posterior a la generación de los datos se presenta a continuación los resultados obtenidos del tiempo promedio y valor Ps.

Tabla 3 Valores obtenidos tráfico medio

NumEs	Udpate	Tmean	Ps
70	1	543,52568	1
70	2	293,660888	1
70	3	210,108175	1
70	4	168,314618	1

70	5	143,302613	1
70	6	126,709712	1
70	7	114,790968	1
70	8	105,794101	1
70	9	98,7602012	1
70	10	93,4009732	1
70	11	89,0380481	1
70	12	85,4726428	1
70	13	82,2925023	1
70	14	80,0079871	1
70	15	77,8474292	0,99998413
70	16	76,1169764	1
70	17	74,8464436	1
70	18	73,9026285	0,99997354
70	19	73,4898158	0,99996241
70	20	73,0075005	0,99994048
70	21	72,8601084	0,99997732
70	22	72,5054545	0,99996753
70	23	72,4370609	0,99982402
70	24	72,5240467	0,99983135
70	25	72,3595852	0,99974286
70	26	72,7056302	0,99954212
70	27	72,5606713	0,99954145
70	28	73,4525787	0,99911565
70	29	74,8205291	0,99863711
70	30	77,5245506	0,99731746
70	31	81,3103207	0,99410906
70	32	86,4164211	0,98681548
70	33	93,0646469	0,97305916
70	34	100,119958	0,9469958
70	35	105,586619	0,91665986

Fuente: Autor

Se observa que, el tiempo promedio empieza a subir a partir de las 33 actualizaciones, este valor se considera en el rango debido a que a partir de la siguiente actualización el valor de Ps empieza a disminuir considerablemente lo que hace que el sistema pierda eficacia.

De acuerdo con los valores obtenidos para el escenario 2 el control del sistema será a partir de la actualización número 33.

3.7.3. Escenario 3

Para el escenario 3 se configuró la red con 35 usuarios capaces de generar hasta 72 actualizaciones al mismo tiempo. Los resultados son los siguientes:

Tabla 4 Valores de tráfico bajo

NumEs	Update	Tmean	Ps
35	1	536,243479	1
35	2	286,62806	1
35	3	202,90661	1
35	4	161,38936	1
35	5	136,479391	1
35	6	119,743497	1
35	7	107,637796	1
35	8	98,9412178	1
35	9	92,1782989	1
35	10	86,3539688	1
35	11	81,9251103	1
35	12	78,2661399	1
35	13	75,0609439	1
35	14	72,3637746	1
35	15	70,2583129	1
35	16	68,3923728	1
35	17	66,6295546	1
35	18	65,19246	1
35	19	64,2893337	1

35	20	63,2108424	1
35	21	62,2130866	1
35	22	61,3782834	1
35	23	60,8361039	1
35	24	60,0486506	1
35	25	59,4703842	1
35	26	58,710505	1
35	27	57,9900944	1
35	28	57,6641178	1
35	29	57,1196202	0,99998358
35	30	57,4157219	0,99998413
35	31	56,9867919	0,99998464
35	32	57,4412303	1
35	33	57,3726678	1
35	34	57,4914624	0,99998599
35	35	57,4910327	1
35	36	57,7865742	0,99998677
35	37	57,8103311	0,99998713
35	38	57,9443748	0,99998747
35	39	57,8765311	0,99993895
35	40	57,8904714	0,99995238
35	41	58,2476938	0,99989547
35	42	57,955925	0,99997732
35	43	58,2477965	0,99991141
35	44	57,9606541	0,99984848
35	45	58,0173546	0,99986243
35	46	57,9640952	0,99980331
35	47	57,8344509	0,99982776
35	48	57,9083327	0,99990079
35	49	57,8552553	0,99982507
35	50	57,8868746	0,9998381
35	51	58,1210666	0,99979458
35	52	58,2988326	0,99967949

35	53	58,68849	0,99960467
35	54	58,8066436	0,99962963
35	55	59,0964855	0,99942857
35	56	59,5769579	0,99942177
35	57	60,2038279	0,99925647
35	58	60,6698199	0,99905583
35	59	61,6840088	0,998636
35	60	62,7859238	0,99824603
35	61	63,5355988	0,99746292
35	62	65,2680672	0,99662826
35	63	66,7304786	0,99509448
35	64	68,9458992	0,99267113
35	65	70,6425525	0,9905641
35	66	72,9327084	0,9848557
35	67	76,0256397	0,97771855
35	68	79,3221984	0,96842437
35	69	81,5356113	0,95806763

Fuente: Autor

Se evidencia que la AoI tiende a aumentar a partir de la actualización número 67, que es el punto donde se debe establecer el control del sistema.

Los resultados del control se los puede apreciar en el Capítulo IV presentado a continuación; además, en cada uno de los valores obtenidos en los resultados obtenidos fueron sometidos a un proceso estadístico para la validación de la hipótesis nula de la investigación.

CAPÍTULO IV. RESULTADOS Y DISCUSIÓN

En este capítulo se detallan los resultados de los escenarios de estudio, en los cuales se hicieron pruebas mediante Q-Learning y se validó la autenticidad de los resultados mediante la prueba de Error de Neural Fiting.

4.1.Resultados Escenario 1

De acuerdo con el escenario establecido, en el escenario de estudio para tráfico alto se conforma de 140 usuarios que envían hasta 72 actualizaciones. A continuación, se evidencia el código de Q-Learning para la obtención de resultados:

```
elseif q==3 %trafico alto
    for U= 1:1:72 %valores que toma U
        gamma=0.7; %parametros Q
        alpha=0.8; %parametros Q
        epsilon=0.2; %parametros Q
        N=[140 U]; %entrada para calcular AoI
        AoIb= myNeuralNetworkFunctionAoIalto(N); %funcion AoI trafico bajo
        AoI(U)=AoIb; %vector que contiene AoI
        M=[140 U AoIb]; %entrada para calcular Ps
        Psb= myNeuralNetworkFunction(M); % funcion Ps trafico bajo
        Ps(U)=Psb; %vector que contiene Ps
        Psc(U)=zeros(1,length(U));
        if Psb >=0.97
            Reward=100; %recompensa maxima
            R(U)=Reward;
            Psc(U)=Psb;
            nn(U)=Psb;
        else
            Reward=(1/-Psb)*100; %recompensa negativa que indica que debemos modificar U
            R(U)=Reward; %matriz reward
            qa=max(find(R(:)>=0)); %ultima celda con mayor recompensa
            ga=R(1,qa);
            qf=min(find(R(:)<=0)); %primera celda con menor recompensa
            gf=R(1,qf);
            %Q=zeros(1,length(U))
            Q=ga+alpha*(gf+gamma*ga) %ecuacion Q learning
            %Q1(U)=zeros(1,length(U))
            p= U(length(U)) - qf;
            Q2=zeros(1,p)
```

Figura 9 Código Q-learning para Escenario 1: Tráfico Alto

Fuente: Autor

En los parámetros de configuración se aprecia los valores asignados los parámetros de la ecuación de Bellman donde:

Gamma= 0.7

Alpha: 0.8

Épsilon= 0.2

N= 140

Reward= 100

A continuación, se presenta el resultado de Ps, donde en tráfico alto el último valor para generar las actualizaciones es de 15:

	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	0.9996	0.9998	1.0002	1.0007	1.0011	1.0013	1.0013	1.0008	0.9997	0.9976	0.9938	0.9870	0.9744	0.9520
2														
3														

Figura 10 Resultados Ps Escenario 1: Tráfico Alto

Fuente: Autor

De igual manera se muestra el control establecido en la red, como se detalla a continuación a partir de la actualización 16, la política establece el valor de 0.9744 para todas las actualizaciones:

	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1	0.9998	1.0002	1.0007	1.0011	1.0013	1.0013	1.0008	0.9997	0.9976	0.9938	0.9870	0.9744	0.9744	0.9744	0.9744
2															

Figura 11 Política de control Escenario 1: Tráfico Alto

Fuente: Autor

En la figura 12 se muestra que la política se establece solo a partir del último valor permitido para las actualizaciones, de acuerdo con lo planteado en el Capítulo II para el escenario de estudio 1 la política se establece a partir de la 16 actualización mientras que para los valores anteriores el valor es 0:

	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1	0	0	0	0	0	0	0	0	0	0	0	0	0.9744	0.9744	0.9744
2															

Figura 12 Valor de la política Escenario 1

Fuente: Autor

Finalmente se muestra las recompensas asignadas las cuales tienen el valor de 100 para las actualizaciones generadas, estas se otorgan hasta el último valor en el que se genera las actualizaciones adecuadas:

	6	7	8	9	10	11	12	13	14	15	16	17
1	0	100	100	100	100	100	100	100	100	100	-105.0370	-109.1693
2												
3												

Figura 13 Recompensas en Escenario 1

Fuente: Autor

Gracias a Neural Fitting se puede validar que no exista overfitting en la red, es decir que el modelo arroje valores reales y muy aproximados a los de la red.




Figura 14 Entrenamiento Escenario 1

Fuente: Autor

En la figura presentada se muestra el aprendizaje de la red en la cual no se evidencia un error significativo para la red, además se evidencia el ajuste de los valores en un rango muy aproximado.

4.2. Resultados Escenario 2

En el escenario de estudio 2 para tráfico medio se configuró 70 usuarios los cuales envían hasta 140 actualizaciones, a continuación, se evidencia el código de Q-Learning para generar los resultados:

```

elseif q==2 %trafico medio
for U= 1:1:140 %valores que toma U
gamma=0.7; %parametros Q
alpha=0.8; %parametros Q
epsilon=0.2; %parametros Q
N=[70 U]; %entrada para calcular AoI
AoIb= myNeuralNetworkFunctionAoImedio(N); %funcion AoI trafico bajo
AoI(U)=AoIb; %vector que contiene AoI
M=[70 U AoIb] ;%entrada para calcular Ps
Psb= myNeuralNetworkFunctionPsmedio(M); % funcion Ps trafico bajo
Ps(U)=Psb; %vector que contiene Ps
Psc(U)=zeros(1,length(U));
if Psb >=0.97
Reward=100; %recompensa maxima
R(U)=Reward;
Psc(U)=Psb;
nn(U)=Psb;
else
Reward=(1/-Psb)*100; %recompensa negativa que indica que debemos modificar U
R(U)=Reward; %matriz reward
qa=max(find(R(:)>=0)); %ultima celda con mayor recompensa
ga=R(1,qa);
qf=min(find(R(:)<=0)); %primera celda con menor recompensa
gf=R(1,qf);
%Q=zeros(1,length(U))

```

Figura 15 Código Q-learning para Escenario 2: Tráfico Medio

Fuente: Autor

En los parámetros de configuración se aprecia los valores asignados a los parámetros de la ecuación de Bellman donde:

Gamma= 0.7

Alpha: 0.8

Épsilon= 0.2

N= 70

Reward= 100

El resultado de Ps, donde en el escenario 2 el último valor para generar las actualizaciones es de 33:

	24	25	26	27	28	29	30	31	32	33	34	35
1	1.0002	0.9992	0.9986	0.9986	0.9988	0.9988	0.9979	0.9950	0.9891	0.9790	0.9636	0.9422
2												

Figura 16 Resultados Ps Escenario 2: Tráfico Medio

Fuente: Autor

Al igual que el escenario 1 se presenta el control establecido en la red, a partir de la actualización 33, la política establece el valor de 0.9790 para todas las actualizaciones:

Control											
1x140 double											
	24	25	26	27	28	29	30	31	32	33	34
1	0.016	1.0002	0.9992	0.9986	0.9986	0.9988	0.9988	0.9979	0.9950	0.9891	0.9790
2											
3											

Figura 17 Política de control Escenario 2: Tráfico Medio

Fuente: Autor

Por otra parte, se establece la política a partir del último valor permitido para las actualizaciones, de acuerdo a lo planteado en el Capítulo II para el escenario de estudio 2 la política se configura desde la actualización 34 mientras que para los valores anteriores el valor es 0:

Ps													
1x140 double													
	25	26	27	28	29	30	31	32	33	34	35	36	
1	0	0	0	0	0	0	0	0	0	0.9790	0.9790	0.9790	
2													

Figura 18 Valor de la política Escenario 3

Fuente: Autor

Las recompensas para el escenario de estudio son de 100 para las conexiones exitosas estas se generan solo hasta las actualizaciones 33:

Ps													
1x140 double													
	25	26	27	28	29	30	31	32	33	34	35	36	
1	100	100	100	100	100	100	100	100	100	-103.7795	-106.1298	-109.3174	
2													

Figura 19 Recompensas en Escenario 2

Fuente: Autor

Neural Fitting permitió evaluar que no exista overfitting en la red, para saber si el modelo es aproximado a los resultados de la red, dicho resultado se muestra a continuación:




Figura 20 Entrenamiento Escenario 2

Fuente: Autor

De acuerdo con los resultados obtenidos en el escenario de estudio se muestra que en entrenamiento se normaliza a partir de las 142 iteraciones, así también no se evidencia un valor significativo en el error de entrenamiento, razón por la cual se puede decir que no existe overfitting.

4.3. Resultados Escenario 3

De acuerdo con el escenario establecido, para el caso de estudio de tráfico bajo, este se configuró con 35 usuarios capaces de enviar hasta 140 actualizaciones:

```

for q= 1:3 %3 escenarios: bajo, medio y alto
if q==1 %trafico bajo
for U= 1:1:140
gamma=0.7; %parametros Q
alpha=0.8; %parametros Q
epsilon=0.2; %parametros Q
N=[35 U]; %entrada para calcular AoI
AoIb= NeuralNetworkFunctionAoIbajo(N); %funcion AoI trafico bajo
AoI(U)=AoIb; %vector que contiene AoI
M=[35 U AoIb]; %entrada para calcular Ps
Psb= myNeuralNetworkFunctionPsbajo(M); % funcion Ps trafico bajo
Ps(U)=Psb; %vector que contiene Ps
Psc(U)=zeros(1,length(U));
if Psb >=0.97
Reward=100; %recompensa maxima
R(U)=Reward;
Psc(U)=Psb;
nn(U)=Psb;
else
Reward=(1/-Psb)*100; %recompensa negativa que indica que debemos modificar U
R(U)=Reward; %matriz reward
qa=max(find(R(:)>=0)); %ultima celda con mayor recompensa
ga=R(1,qa);
qf=min(find(R(:)<=0)); %primera celda con menor recompensa
gf=R(1,qf);
%Q=zeros(1,length(U))

```

Figura 21 Código Q-learning para Escenario 3: Tráfico Bajo

Fuente: Autor

Donde:

Gamma= 0.7

Alpha: 0.8

Épsilon= 0.2

N= 35

Reward= 100

El resultado de Ps, donde en tráfico bajo el último valor para generar las actualizaciones es de 67:

	58	59	60	61	62	63	64	65	66	67	68	69
1	0.9990	0.9988	0.9985	0.9979	0.9969	0.9953	0.9929	0.9893	0.9842	0.9775	0.9689	0.9583
2												

Figura 22 Resultados Ps Escenario 3: Tráfico Bajo

Fuente: Autor

La política de control se aplica desde la actualización 68 en donde se establece el valor de 0.9775 para las demás actualizaciones.

	59	60	61	62	63	64	65	66	67	68	69	70
1	1.9778	1.9775	1.9769	1.9759	1.9743	1.9719	1.9683	1.9632	1.9565	0.9775	0.9775	0.9775
2												

Figura 23 Política de control Escenario 3: Tráfico Bajo

Fuente: Autor

Al igual que en los casos anteriores la política se ejecuta a partir solo del último valor válido para generar actualizaciones. En el escenario 3 dicho valor se establece en U= 68, para las demás actualizaciones el valor de la política es de 0.

	57	58	59	60	61	62	63	64	65	66	67	68
1	0	0	0	0	0	0	0	0	0	0	0	0.9775
2												

Figura 24 Valor de la política Escenario 3

Fuente: Autor

Finalmente se presenta la configuración de recompensas que se establece en el valor de 100 para las primeras 68 actualizaciones:

	58	59	60	61	62	63	64	65	66	67	68	69
1	100	100	100	100	100	100	100	100	100	100	-103.2124	-104.3492
2												

Figura 25 Recompensas en Escenario 3

Fuente: Autor

El algoritmo de neural Fitting permitió validar que la ausencia overfitting en el escenario, para comprobar que los valores arrojados sean aproximados:

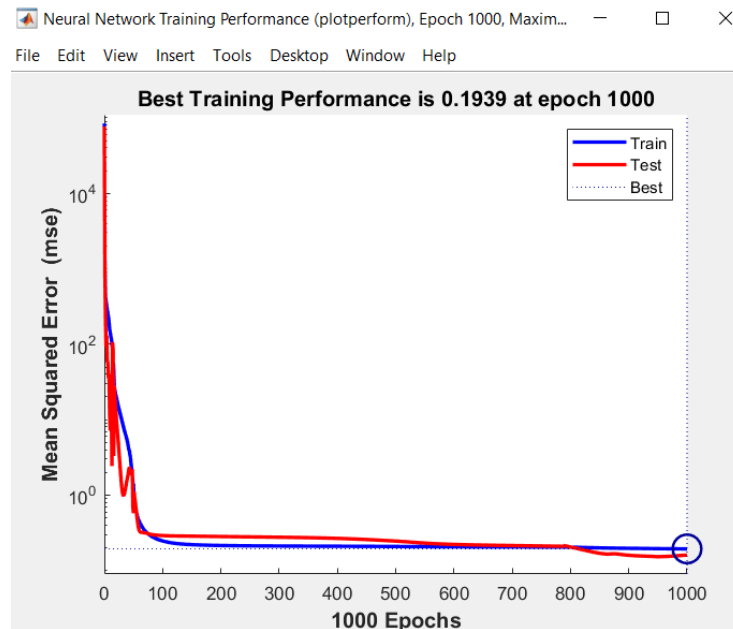


Figura 26 Entrenamiento Escenario 3

Fuente: Autor

Como se aprecia en la figura presentada, no existe un error significativo en el entrenamiento de la red, razón por la cual se dice que el sistema se encuentra adecuado con un performance de 0.1939 sin presencia de overfitting.

4.4. Análisis estadístico de resultados

ANÁLISIS COMPARATIVO ENTRE LOS 3 ESCENARIOS SIN CONTROL

Como se explicó en el capítulo III, se utilizó 3 escenarios con muestras de 35, 70 y 140 usuarios los cuales fueron obtenidos a ML para el aprendizaje y control de la AoI.

Tabla 5 Resumen datos escenarios sin control

	Escenario sin control	Casos					
		Válidos		Perdidos		Total	
		N	Porcentaje	N	Porcentaje	N	Porcentaje
Antigüedad de la Información	A(140)	72	100,0%	0	0,0%	72	100,0%
	M(70)	140	100,0%	0	0,0%	140	100,0%
	B(35)	140	100,0%	0	0,0%	140	100,0%

Fuente: Autor

En los tres casos presentados se evidencia un porcentaje de datos válidos del 100%, lo que significa que toda la información procesada no tiene errores. En la figura 27 se muestra la dispersión de la AoI en los escenarios sin control:




Figura 27 Antigüedad de la Información

Fuente: Autor

En el diagrama de cajas podemos observar que el 25% de todos los datos en los 3 escenarios planteados cuentan con una baja dispersión en el rango inferior, mientras que en el 25% correspondiente al rango superior existe baja dispersión únicamente en el escenario de 35

usuarios muy contrario a los escenarios de 140 y 70 usuarios respectivamente. Este fenómeno era esperado debido a que la $AoI(t)$ es un proceso estocástico que aumenta linealmente con t entre actualizaciones provocando estos valores.

Para establecer la diferencia entre los resultados se presenta la prueba ANOVA en donde se realizó la prueba de hipótesis correspondiente a la comparación de medias de los tres escenarios de control:

- Hipótesis Nula (H_0)
- $H_0 = \mu_1 = \mu_2 = \mu_3$
- Hipótesis alternativa (H_1)
- $\mu_i \neq \mu_j \quad i, j = 1, 2, 3$
- $\mu_1 =$ Media de la antigüedad de la información en tráfico Alto (Escenario 1) o $\mu_2 =$ Media de la antigüedad de la información en tráfico Medio (Escenario 2) o $\mu_3 =$ Media de la antigüedad de la información en tráfico Bajo (Escenario 3)

Tabla 6 ANOVA de un factor

Antigüedad de la Información

	N	Media	Desviación típica	Error típico	Intervalo de confianza para la media al 95%		Mínimo	Máximo
					Límite inferior	Límite superior		
A(140)	72	2043,3089	3050,32701	359,48449	1326,5172	2760,1006	99,74	14296,99
M(70)	140	1272,9585	1998,95097	168,94219	938,9298	1606,9873	72,36	8714,42
B(35)	140	112,2690	61,48443	5,19638	101,9948	122,5431	56,99	536,24
Total	352	968,8923	2008,06961	107,03047	758,3906	1179,3940	56,99	14296,99

Fuente: Autor

Tabla 7 ANOVA de un factor para análisis de Sig.

Antigüedad de la Información

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	198791095,431	2	99395547,715	28,514	,000
Intra-grupos	1216561498,743	349	3485849,567		
Total	1415352594,174	351			

Fuente: Autor

Como se evidencia $p\text{-valor} = 0.000 < 0,005$ razón por la cual se acepta la hipótesis alternativa, en otras palabras, las medias son significativamente distintas. Finalmente se muestra la media obtenida de los resultados obtenidos de la AoI.




Figura 28 Media Antigüedad de la Información

Fuente: Autor

De acuerdo con los resultados se aprecia que:

- Escenario alto en comparación con el escenario bajo existe un decremento en la media del 94.51%
- Escenario alto en comparación con el escenario medio existe un decremento en la media del 37.70%
- Escenario medio en comparación con el escenario bajo existe un decremento en la media del 91.18%

Al correlacionar la parte teórica-práctica con los valores recolectados a través de los análisis estadísticos se observa como el 50% de valores inferiores a la media llevan una baja dispersión debido a que en dicho rango el valor de P_s se encuentra dentro del valor adecuado (mayor o igual a 0.97). Los valores por encima de la media llevan una significativa dispersión como podemos notarlo en la desviación típica que aumenta acorde al número de usuarios de cada escenario y esto ocurre debido a que la variable P_s ya no se encuentra dentro de los rangos establecidos provocando inestabilidad en la red.

En la tabla ANOVA de un factor la variable Sig. nos ayuda a determinar nuestro p-valor que en el caso de ser menor a 0.05 se acepta la hipótesis alternativa (u_1 distinto de u_2 distinto de u_3) y en el caso de ser mayor se acepta la hipótesis nula ($u_1=u_2=u_3$). Como podemos observar en este caso se acepta h_1 .

A fin identificar que los subconjuntos de datos no posean gran diferencia se presenta a continuación la prueba POST HOC con la Variable dependiente: Antigüedad de la Información.

Tabla 8 PRUEBA POST HOC en comparaciones múltiples

HSD de Tukey

(I) Escenario control	sin (J) Escenario control	Diferencia de medias (I-J)	Error típico	Sig.	Intervalo de confianza al 95%	
					Límite inferior	Límite superior
A(140)	M(70)	770,35040*	270,76466	,013	133,0363	1407,6645
	B(35)	1931,03998*	270,76466	,000	1293,7258	2568,3541
M(70)	A(140)	-770,35040*	270,76466	,013	-1407,6645	-133,0363
	B(35)	1160,68958*	223,15432	,000	635,4386	1685,9406
B(35)	A(140)	-1931,03998*	270,76466	,000	-2568,3541	-1293,7258
	M(70)	-1160,68958*	223,15432	,000	-1685,9406	-635,4386

Fuente: Autor

De acuerdo con el valor obtenido se aprecia que la diferencia de medias es significativa al nivel 0.05, a continuación, se presenta la prueba POST HOC para el subconjunto alfa igual a 0,05 de la AoI, con un tamaño muestral de 106,479.

Tabla 9 POST HOC para Antigüedad de la Información

HSD de Tukey^{a,b}

Escenario sin control	N	Subconjunto para alfa = 0.05		
		1	2	3
B(35)	140	112,2690	1272,9585	2043,3089
M(70)	140			
A(140)	72			
Sig.		1,000	1,000	1,000

Fuente: Autor

ANÁLISIS COMPARATIVO ENTRE LOS 3 ESCENARIOS CONTROLADOS

A continuación, se presenta el resumen de los datos procesados en los tres escenarios planteados:

Tabla 10 Resumen datos escenarios controlados

	Comparación	Casos					
		Válidos		Perdidos		Total	
		N	Porcentaje	N	Porcentaje	N	Porcentaje
Antigüedad de la información	A(140)	72	100,0%	0	0,0%	72	100,0%
	M(70)	140	100,0%	0	0,0%	140	100,0%
	B(35)	140	100,0%	0	0,0%	140	100,0%

Fuente: Autor

Los datos poseen una validez del 100% de efectividad en los tres escenarios planteados, es así como se presenta la dispersión de los datos:




Figura 29 Diagrama Dispersión Antigüedad de la Información

Fuente: Autor

Como se puede apreciar en el diagrama de cajas, en el escenario de 140 y 70 usuarios prácticamente la dispersión es nula, notando así el control que se aplica sobre los datos a través de ML. A continuación, se presenta los resultados en la ANOVA de los escenarios controlados:

- Hipótesis Nula (H_0)
- $H_0 = \mu_1 = \mu_2 = \mu_3$
- Hipótesis alternativa (H_1) o $\mu_i \neq \mu_j, i, j = 1, 2, 3$
- $\mu_1 =$ Media de la AoI en tráfico Alto (Escenario 1)
- $\mu_2 =$ Media de la AoI en tráfico Medio (Escenario 2)
- $\mu_3 =$ Media de la AoI en tráfico Bajo (Escenario 3)

Tabla 11 ANOVA de un factor

Antigüedad de la información

	N	Media	Desviación típica	Error típico	Intervalo de confianza para la media al 95%		Mínimo	Máximo
					Límite inferior	Límite superior		
A(140)	72	116,9287	60,29763	7,10614	102,7595	131,0980	99,74	555,94
M(70)	140	97,4061	44,12592	3,72932	90,0325	104,7796	72,36	543,53
B(35)	140	77,9307	46,43334	3,92433	70,1716	85,6898	57,54	536,22
Total	352	93,6534	50,75121	2,70505	88,3333	98,9736	57,54	555,94

Fuente: Autor

Tabla 12 ANOVA de un factor para análisis de Sig.

Antigüedad de la información

	Suma de cuadrados	gl	Media cuadrática	F	Sig.
Inter-grupos	75585,494	2	37792,747	15,920	,000
Intra-grupos	828480,213	349	2373,869		
Total	904065,707	351			

Fuente: Autor

En la tabla ANOVA de un factor la variable Sig. nos ayuda a determinar nuestro p-valor que en el caso de ser menor a 0.05 se acepta la hipótesis alternativa (μ_1 distinto de μ_2 distinto de μ_3) y en el caso de ser mayor se acepta la hipótesis nula ($\mu_1 = \mu_2 = \mu_3$). Como podemos observar en este caso se acepta H_1 .

Como se evidencia p-valor=0.000 < 0,005 razón por la cual se acepta la hipótesis alternativa, en otras palabras, las medias son significativamente distintas.

Finalmente, se detalla la media obtenida de los escenarios controlados:




Figura 30 Diagrama Dispersión Antigüedad de la Información
Fuente: Autor

ANÁLISIS COMPARATIVO EN ESCENARIO 1 CON Y SIN CONTROL

En la tabla 13 se muestra los valores estadísticos obtenidos en la comparación del escenario 1 con y sin control:

- Hipótesis Nula (H_0)
- $H_0 = \mu_1 = \mu_2$
- Hipótesis alternativa (H_1)
- $\mu_1 \neq \mu_2$
- $\mu_1 =$ Media de la antigüedad de la información en el escenario 1 antes del control
- $\mu_2 =$ Media de la antigüedad de la información en el escenario 2 después del control

Tabla 13 Estadísticos de grupo Escenario 1

	Con Control	N	Media	Desviación típ.	Error típ. de la media
Antigüedad de la SC1		72	2043,3089	3050,32701	359,48449
Información Escenario alto CC1		72	116,9287	60,29763	7,10614

Fuente: Autor

Como podemos observar en la tabla obtenida a través del software SPSS el valor de la Media es significativamente menor cuando aplicamos el control a través de machine learning, como nos indica la parte teórica, la tendencia de la métrica AoI debe ser disminuir para así mantener a la variable Ps dentro del rango menor o igual a 0.97.

Tabla 14 Prueba de muestras independientes

		Prueba de Levene para la igualdad de varianzas		Prueba T para la igualdad de medias						
		F	Sig.	t	gl	Sig. (bilateral)	Diferencia de medias	Error típ. de la diferencia	95% Intervalo de confianza para la diferencia	
									Inferior	Superior
Aol Escenario alto	Varianzas Iguales	83,686	,000	5,358	142	,000	1926,3801	359,55472	1215,60848	2637,15190
	Varianzas diferentes			5,358	71,055	,000	1926,3801	359,55472	1209,45815	2643,30223

Fuente: Autor

De acuerdo con los valores obtenidos se aprecia que:

- P valor = sig bilateral
- Se acepta la hipótesis alternativa, se comprueba que posterior a la optimización a través de machine learning existe un decremento en el valor de la media, el cual porcentualmente hablando corresponde al 94.27%.

ANÁLISIS COMPARATIVO EN ESCENARIO 2 CON Y SIN CONTROL

A continuación, se presenta los valores obtenidos del escenario 2:

- Hipótesis Nula (H0)
- $H_0 = \mu_1 = \mu_2$
- Hipótesis alternativa (H1)
- $\mu_1 \neq \mu_2$
- μ_1 = Media de la antigüedad de la información en el escenario 1 antes del control
- μ_2 = Media de la antigüedad de la información en el escenario 2 después del control
-

Tabla 15 Estadísticos de grupo Escenario 2

	Escenario 2 con y sin control	N	Media	Desviación típ.	Error típ. de la media
Antigüedad de la información	SC2	140	1272,9585	1998,95097	168,94219
	CC2	140	97,4061	44,12592	3,72932

Fuente: Autor

De acuerdo con la tabla obtenida a través del software SPSS el valor de la Media es significativamente menor cuando aplicamos el control a través de machine learning, como nos indica la parte teórica, la tendencia de la métrica AoI debe ser disminuir para así mantener a la variable Ps dentro del rango menor o igual a 0.97.

Tabla 16 Prueba de muestras independientes Escenario 2

		Prueba de Levene para la igualdad de varianzas		Prueba T para la igualdad de medias						
		F	Sig.	t	gl	Sig. (bilateral)	Diferencia de medias	Error típ. de la diferencia	95% Intervalo de confianza para la diferencia	
									Inferior	Superior
Aol Escenario medio	Varianzas Iguales	141,385	,000	6,957	278	,000	1175,55248	168,9833	842,90302	1508,2019
	Varianzas diferentes			6,957	139,135	,000	1175,55248	168,9833	841,44522	1509,6597

Fuente: Autor

En los valores obtenidos se aprecia que:

- P valor = sig bilateral; 0.000
- Se acepta la hipótesis alternativa, se comprueba que posterior a la optimización a través de machine learning existe un decremento en el valor de la media, el cual porcentualmente hablando corresponde al 92.34%.

ANÁLISIS COMPARATIVO EN ESCENARIO 3 CON Y SIN CONTROL

A continuación, se aprecia los valores obtenidos del Escenario 3:

- Hipótesis Nula (H0)
- $H_0 = \mu_1 = \mu_2$
- Hipótesis alternativa (H1)
- $\mu_1 \neq \mu_2$
- μ_1 = Media de la AoI en el escenario 1 antes del control
- μ_2 = Media de la AoI en el escenario 2 después del control

Tabla 17 Estadísticos de grupo

	Escenario 3	N	Media	Desviación típ.	Error típ. de la media
Aoi	SC3	140	112,2690	61,48443	5,19638
	CC3	140	77,9307	46,43334	3,92433

Fuente: Autor

Como podemos observar en la tabla obtenida a través del software PSS el valor de la Media es significativamente menor cuando aplicamos el control a través de machine learning, como nos indica la parte teórica, la tendencia de la métrica AoI debe ser disminuir para así mantener a la variable Ps dentro del rango menor o igual a 0.97.

Finalmente se presenta los resultados de las muestras independiente del escenario 3:

Tabla 18 Prueba de muestras independientes Escenario 3

		Prueba de Levene para la igualdad de varianzas		Prueba T para la igualdad de medias						
		F	Sig.	t	gl	Sig. (bilateral)	Diferencia de medias	Error típ. de la diferencia	95% Intervalo de confianza para la diferencia	
									Inferior	Superior
Aoi Escenar io bajo	Varianzas Iguales	37,173	,000	5,273	278	,000	34,3382	6,51174	21,5196	47,1568
	Varianzas diferentes									

Fuente: Autor

De acuerdo con los valores obtenidos se confirma que:

- P valor = sig. bilateral; 0.000
- Se acepta la hipótesis alternativa, se comprueba que posterior a la optimización a través de machine learning existe un decremento en el valor de la media, el cual porcentualmente hablando corresponde al 30.59%

CAPÍTULO V. CONCLUSIONES y RECOMENDACIONES

Se concluye que:

- La conexión mMTC se encuentra orientada a la comunicación masiva de usuarios, esta entra en tendencia para las redes 5G las cuales se han diseñado con el fin de tener mejor interacción con IoT, a fin de presentar conexiones con el menor retardo posible.
- El estudio realizado se basa en analizar el comportamiento de la antigüedad de la información (AoI), métrica en la cual se estableció parámetros de control mediante machine learning y aprendizaje reforzado para tres escenarios con diferentes números de usuarios los cuales fueron 35, 70 y 140.
- El aprendizaje reforzado en Matlab permitió establecer los parámetros de control en los escenarios propuestos, estos fueron establecidos de acuerdo a la cantidad de tráfico generado por los usuarios dentro del sistema los cuales variaron de acuerdo con la cantidad de usuarios.
- La comprobación de los valores y estructuras de control en los casos de estudio se realizó a través de aprendizaje neural, el cual es otro método de machine learning en Matlab, este permitió constatar la ausencia de overfitting en los sistemas.

Se recomienda:

- Analizar los diferentes algoritmos de ML desarrollados o propuestos por el software MATLAB a fin de saber si existe algún modelo adaptativo a redes IoT.
- Es importante siempre considerar los resultados dependerán siempre de las entradas del esquema razón por la cual se debe tener identificado las variables de entrada y salida para la red.
- Verificar que los valores de predicción sean aproximados a los resultados reales de la red, además se debe aclarar que la eficiencia de ML es directamente proporcional de la cantidad de datos ingresados.
- Realizar más pruebas de funcionamiento y modelamiento de redes IoT mediante la tecnología ML para mayor precisión en estudios futuros.

BIBLIOGRAFÍA

- [1] A. K. Guamo Morocho, “Evaluación de escenarios de comunicaciones masivas de tipo máquina (mMTC) desde la perspectiva de la Antigüedad de la Información (AoI),” Tesis de máster, Universitat Politècnica de València, 2020.
- [2] H. Shariatmadari, R. Ratasuk, S. Iraj, A. Laya, T. Taleb, R. Jäntti y A. Ghosh, “Machine-type communications: current status and future perspectives toward 5g systems,” *IEEE Communication Letters*, vol. 53, no. 9, pp. 10-17, Septiembre 2015.
- [3] J. M. Becerra Pareja, “Mejoramiento de la cobertura de las estaciones base ENB en la red celular LTE/EPC utilizando latécnica PSD boosting,” Tesis de máster, UNIANDES, Bogotá, 2017.
- [4] P. I. Satán, “Análisis del rendimiento del canal de acceso aleatorio en la tecnología narrowband IoT (NB-IoT) para la comunicación máquina a máquina (M2M),” Tesis de grado, UNACH, Riobamba, 2020.
- [5] P. Popovski, K. F. Trillingsgaard, O. Simeone y G. Durisi, “5G Wireless Network Slicing for eMBB, URLLC, and mMTC: A Communication-Theoretic View,” *IEEE Communication Letters*, vol. 6, pp. 1-15, 2018.
- [6] Rohde y Schwarz. (2022). Optimización del tráfico de datos generado por dispositivos IoT y móviles [Online]. Available: https://www.rohde-schwarz.com/lat/aplicaciones/optimizaci-n-del-tr-fico-de-datos-generado-por-dispositivos-iot-y-m-viles-ficha-de-aplicacion_56279-35727.html
- [7] I. Krikidis, “Average Age of Information in Wireless Powered Sensor Networks,” *IEEE Communication Letters*, vol. 8, no. 2, pp. 1-4, Abril 2019.
- [8] I. Kadota, A. Sinha y E. Modiano, “Optimizing Age of Information in Wireless Networks with Throughput Constraints,” *IEEE Communication Letters*, pp. 1844-1852, Octubre 2018.
- [9] D. A. Santander González, “Evaluación y caracterización del impacto del tiempo de backoff en la red de acceso radio de IOT celular con tráfico masivo,” Tesis de grado, UNACH, Riobamba, 2021.
- [10] E. Ramos Chagoya. (2018, julio 01). Métodos y técnicas de investigación [Online]. Available: <https://www.gestiopolis.com/metodos-y-tecnicas-de-investigacion/>

- [11] R. S. Sutton y A. G. Barto, *Reinforcement learning: An introduction*. Cambridge: The MIT Press, 2014,2015
- [12] E. Escobar Gallardo, “Sistema de monitoreo energético y control domótico basado en tecnología internet de las cosas,” *Investigación & Desarrollo*, vol. 18, no. 1, pp. 103-116, 2018.
- [13] D. Evans, “Internet de las cosas. Cómo la próxima evolución de Internet lo cambia todo”, Cisco IBSG, Informe técnico, 2021.
- [14] J. Salazar y S. Silvestre, *Internet de las cosas*. Chequia: České vysoké učení technické v Praze Fakulta elektrotechnická, 2016.
- [15] L.C. García, E.D. Ceballos Burbano, A.R. Torres Gómez, F.E. Sacristán Bohórquez y J.D. Alvarado Moreno, “Internet de las Cosas Hacia una educación inteligente,” *UMB Virtual*, pp. 10-17, Agosto 2018.
- [16] Casadomo. (2020, noviembre 20). El MIT diseña un sistema de red neuronal de aprendizaje profundo para dispositivos IoT [Online]. Available: <https://www.casadomo.com/2020/11/20/mit-disena-sistema-red-neuronal-aprendizaje-profundo-dispositivos-iot>
- [17] Appandweb. (2021, abril 28). Ventajas y desventajas del Internet de las Cosas [Online]. Available: <https://www.appandweb.es/blog/ventajas-desventajas-internet-cosas/>
- [18] Winecta. (2019, diciembre 24). ¿Internet de las Cosas? Ventajas y Desventajas [Online]. Available: <https://www.wincta.com/internet-de-las-cosas-ventajas-desventajas/#:~:text=Puede%20llegar%20a%20haber%20falta,tener%20no%20es%20nada%20bueno.>
- [19] M.A. Azar, M.A. Tapia, J.L. García y J. M. Pérez, “Inteligencia Artificial de las Cosas,” Universidad Nacional de Jujuy, pp.1-5.
- [20] A. Senovilla Tejedor, “Inteligencia Artificial y Aprendizaje Automático en Arquitectura,” Tesis de grado, Universidad Politécnica de Madrid, Madrid, 2020.
- [21] T. P. Mendieta, J. F. Herrera y A. L. Jiménez, “La Capacidad del IOT de Transformar el Futuro,” *Avenir*, vol. 3, no. 1, pp. 15-18, 2019.

- [22] A.D. Jiménez Alfaro y J.V. Díaz Ospina, “Revisión sistemática de literatura: Técnicas de aprendizaje automático (machine learning),” *Cuaderno Activa*, vol.13, pp. 113-121, 2021
- [23] IBM. (2022). ¿Qué es Machine Learning? [Online]. Available: <https://www.ibm.com/mx-es/analytics/machine-learning>
- [24] X. Bolaños. (2020, septiembre 11). Ciudades Inteligentes: Su Relación con IoT y Machine Learning [Online]. Available: <https://www.encora.com/es/blog/ciudades-inteligentes-su-relacion-con-iot-y-machine-learning#:~:text=Machine%20learning%20junto%20con%20Internet,optimizar%20todo%20tipo%20de%20servicios>.
- [25] R. Biella y P. Veronesi. (2021, abril 20). Aprendizaje automático: una gran oportunidad para las plataformas de IoT [Online]. Available: <https://www.pdxeng.ch/es/2021/04/20/machine-learning-opportunity-for-iot-platforms/>
- [26] F. Zantalis, G. Koulouras, S. Karabetsos y D. Kandris, “A Review of Machine Learning and IoT in Smart Transportation,” *Future Internet*, vol. 11, no. 94, pp. 1-23, 2019
- [27] H. Sánchez, C. Reyes y K. Mejía. Manual de términos en investigación científica, tecnológica y humanística. Lima-Perú: Universidad Ricardo, Palma 2018.
- [28] A. Álvarez. (2020). Clasificación de las investigaciones [Online]. Available: <https://repositorio.ulima.edu.pe/handle/20.500.12724/10818>
- [29] L. Castellanos. (2017, marzo 02). Técnica de Observación [Online]. Available: <https://lcmetodologiainvestigacion.wordpress.com/2017/03/02/tecnica-de-observacion/>

ANEXOS

1. RESUMEN DE ITERACIONES NEURAL FITTING ESCENARIO 1

Neural Network Training (ntraintool)

Neural Network

Algorithms

Data Division: Random (dividerand)
Training: Bayesian Regularization (trainbr)
Performance: Mean Squared Error (mse)
Calculations: MEX

Progress

Epoch:	0	1000 iterations	1000
Time:		0:01:59	
Performance:	1.21	4.67e-07	0.00
Gradient:	3.17	4.20e-06	1.00e-07
Mu:	0.00500	5.00	1.00e+10
Effective # Param:	41.0	28.3	0.00
Sum Squared Param:	280	593	0.00

Plots

- Performance (plotperform)
- Training State (plottrainstate)
- Error Histogram (ploterrhist)
- Regression (plotregression)
- Fit (plotfit)

Plot Interval: 1 epochs

✓ **Maximum epoch reached.**

Stop Training Cancel

2. RESUMEN DE ITERACIONES NEURAL FITTING ESCENARIO 2

Neural Network Training (nntraintool)

Neural Network

Algorithms

Data Division: Random (dividerand)
 Training: Bayesian Regularization (trainbr)
 Performance: Mean Squared Error (mse)
 Calculations: MEX

Progress

Epoch:	0	613 iterations	1000
Time:		0:01:10	
Performance:	8.81e+07	1.05e+04	0.00
Gradient:	1.50e+08	135	1.00e-07
Mu:	0.00500	5.00e+10	1.00e+10
Effective # Param:	31.0	16.8	0.00
Sum Squared Param:	2.76e+03	572	0.00

Plots

- Performance (plotperform)
- Training State (plottrainstate)
- Error Histogram (ploterrhist)
- Regression (plotregression)
- Fit (plotfit)

Plot Interval: 1 epochs

'Maximum MU reached.'

3. RESUMEN ITERACIONES NEURAL FITTING ESCENARIO 3

Neural Network Training (ntraintool)

Neural Network

Algorithms

Data Division: Random (dividerand)
 Training: Bayesian Regularization (trainbr)
 Performance: Mean Squared Error (mse)
 Calculations: MEX

Progress

Epoch:	0	1000 iterations	1000
Time:		0:00:02	
Performance:	8.43e+04	0.194	0.00
Gradient:	2.18e+05	1.43	1.00e-07
Mu:	0.00500	0.500	1.00e+10
Effective # Param:	31.0	21.6	0.00
Sum Squared Param:	2.76e+03	6.42e+03	0.00

Plots

- Performance (plotperform)
- Training State (plottrainstate)
- Error Histogram (ploterrhist)
- Regression (plotregression)
- Fit (plotfit)

Plot Interval: 1 epochs

✔ **Maximum epoch reached.**

Stop Training
Cancel

4. RESUMEN DE ITERACIONES Q LEARNING

Command Window

L =

Columns	1	2	3	4	5	6	7	8	9	10	11
Columns 1 through 11	1.0000	1.0000	1.0001	1.0000	0.9999	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Columns 12 through 22	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Columns 23 through 33	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Columns 34 through 44	0.9999	0.9999	0.9999	0.9999	0.9999	0.9999	1.0000	1.0000	1.0000	1.0000	1.0000
Columns 45 through 55	1.0000	1.0000	0.9999	0.9999	0.9999	0.9998	0.9997	0.9996	0.9995	0.9995	0.9994
Columns 56 through 66	0.9993	0.9991	0.9990	0.9988	0.9985	0.9979	0.9969	0.9953	0.9929	0.9893	0.9842
Columns 67 through 68	0.9775	73.4301									

5. TABLAS OBTENIDAS MEDIANTE Q-LEARNING

Workspace

Name	Value
alpha	0.8000
Aol	1x140 double
Aol67	75.9619
Aolb	210.9029
C	[35,67,75.9619]
Control	1x140 double
epsilon	0.2000
ga	100
gamma	0.7000
gf	-103.2124
M	[35,140,210.9029]
N	[35,140]
nn	1x67 double
O	[35,67]
p	72
Ps	1x140 double
Psb	0.0722
Psbcb	0.9775
Psc	1x140 double
Pscb	1x140 double
Q	73.4301
Q1	1x140 double
Q2	1x72 double
qa	67
qf	68
R	1x140 double
Reward	-1.3842e+03
U	140
Uc	140