



UNIVERSIDAD
DE PIURA

REPOSITORIO INSTITUCIONAL
PIRHUA

OPTIMIZACIÓN DE LA EFICIENCIA DEL ESPECTRO RADIOELÉCTRICO UTILIZANDO REDES NEURONALES EN AL UNAP

Carlos González-Aspajo

Piura, mayo de 2015

Facultad de Ingeniería

Maestría en Dirección Estratégica en Tecnologías de la Información

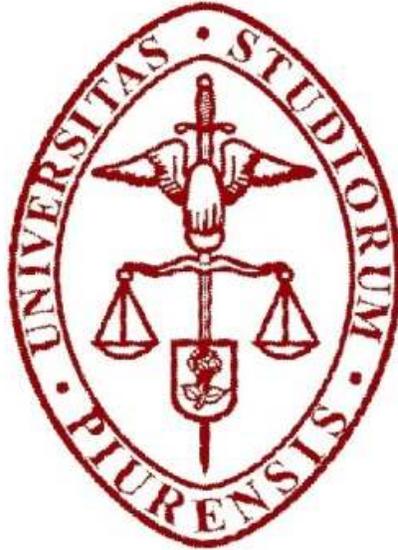
González, C. (2015). *Optimización de la eficiencia del espectro radioeléctrico utilizando redes neuronales en al UNAP* (Tesis de máster en Dirección Estratégica de Tecnologías de la Información). Universidad de Piura. Facultad de Ingeniería. Piura, Perú.



Esta obra está bajo una [licencia Creative Commons Atribución-NoComercial-SinDerivadas 2.5 Perú](#)

[Repositorio institucional PIRHUA – Universidad de Piura](#)

UNIVERSIDAD DE PIURA
FACULTAD DE INGENIERÍA



“Optimización de la Eficiencia del Espectro Radioeléctrico Utilizando Redes Neuronales en la UNAP”

“Tesis para Optar el Grado de
Máster en Dirección Estratégica en Tecnologías de la Información”

Carlos González Aspajo

Asesor: Federico Wiese López

Piura, Mayo 2015

DEDICO este trabajo a mis hijos
como prueba de que los tiempos han cambiado
y que la superación constante debe ser nuestra nueva forma de vivir.

Resumen

El presente trabajo de tesis, abarca el tema de las redes neuronales artificiales y su capacidad para aprender y pronosticar el consumo de ancho de banda en el espectro radioeléctrico de internet, para lo cual se emplearan dos algoritmos muy conocidos como son el de Retropropagación y el de Levenberg-Marquardt.

Ambos algoritmos serán evaluados para determinar cuál de ellos posee el menor error promedio al momento de realizar el pronóstico de consumo de ancho de banda.

Según las evaluaciones previas se pretende demostrar el algoritmo de redes neuronales artificiales de Levenberg-Marquardt es el óptimo para la tarea de pronóstico de consumo de ancho de banda en la Universidad Nacional de la Amazonia Peruana.

Abstract

This thesis covers the topic of artificial neural networks and their ability to learn and forecast the consumption of bandwidth in the radio spectrum of internet, for which two algorithms very met like the Backpropagation was employed and Levenberg-Marquardt.

Both algorithms will be evaluated to determine which one has the lowest average error at the time of the forecast bandwidth consumption.

According to previous assessments it is to demonstrate the artificial neural network algorithm Levenberg-Marquardt is optimal for the task of forecasting bandwidth consumption at the National University of the Peruvian Amazon.

Índice general

Capítulo 1.	01
Introducción	01
1.1. Contexto	01
1.2. Antecedentes	04
1.3. Justificación	05
1.4. Problemática	06
1.5. Características del problema	06
Capítulo 2.	09
Objetivos, hipótesis, alcance	09
2.1. Objetivo general	09
2.2. Objetivos específicos	09
2.3. Hipótesis	09
2.4. Alcance del proyecto	10
Capítulo 3.	11
Estado del arte	11
3.1. Redes neuronales	11
3.2. Tipos de redes neuronales: Retropropagación y Levenger-Marquardt	24
3.3. Porcentaje de erro absoluto MAPE	30
3.4. Ancho de banda	32
3.5. Eficiencia del ancho de banda en el espectro radioelétrico	44
3.6. Plan de frecuencia del espectro radioelétrico	47
3.7. Tipo de soluciones para la optimización del consumo de ancho de banda	52
Capítulo 4.	55
Solución propuesta	55
4.1. Descripción	55
4.2. Aplicación del software de recolección de datos	56
4.3. Conversión de datos en información	58
4.4. Análisis de consumo de ancho de banda	60
4.5. Análisis de ruido	61
4.6. Aplicación de algoritmos de procedimientos	62
4.7. Calculo de MAPE	62
4.8. Identificación del modelo neuronal de menor MAPE	63
4.9. Aplicación de minería de datos para la construcción de modelos de redes neuronales	63

4.10. Identificación de valores óptimos de las medidas de desempeño de los modelos	64
Capítulo 5.	65
Metodología de investigación	65
5.1. Selección de tema	65
5.2. Identificación del problema	66
5.3. Revisión de la literatura	66
5.4. Definición del tipo de investigación	69
5.5. Establecer hipótesis	70
5.6. Diseño de investigación	70
5.7. Población y muestra	70
5.8. Recolección de datos	71
5.9. Análisis de datos	72
5.10. Presentación de resultados	73
Capítulo 6.	87
Análisis de resultados	87
6.1. Comparación de resultado	87
6.2. Pronostico optimizado de frecuencia en el consumo de ancho de banda en el espectro radioeléctrico de la Universidad Nacional de la Amazonia Peruana.	88
Conclusiones y recomendaciones	89
7.1. Conclusiones	89
7.2. Recomendaciones	90
Bibliografía	91

Índice de figuras

Figura 1. Estructura de comunicaciones de la UNAP	03
Figura 2. Plataforma de servidores de la UNAP	04
Figura 3. Frecuencia que se utiliza el software de la UNAP	07
Figura 4. Beneficios al hacer uso del software	07
Figura 5. Problemas en el uso de programa	08
Figura 6. Labores académicas condicionadas a internet	08
Figura 7. Modelo biológico de una neurona	13
Figura 8. Modelo artificial de una neurona	13
Figura 9. Modelo neuronal	14
Figura 10. Iones en la neurona dentro y fuera de la membrana celular.	16
Figura 11. Potencial de acción	17
Figura 12. Función de respuesta de la neurona biológica ante estímulos del exterior	17
Figura 13. Patrones de disparo: a) regular, b) en paquete de pulsos en una neurona piramidal del córtex, c) disparo de una célula de Purkinje del cerebro	18
Figura 14. Modelo genérico de neurona artificial	20
Figura 15. Modelo de neurona estándar	21
Figura 16. Interacción entre una neurona presináptica y otra postsináptica	22
Figura 17. Arquitectura unidireccional de tres capas, de entrada, oculta y de salida.	23
Figura 18. Ejemplos de arquitecturas neuronales	24
Figura 19. Algoritmo de Retropropagación (BP)	27
Figura 20. Algoritmo Levenberg–Marquardt (LM).	30
Figura 21. Ancho de banda	32
Figura 22. Ganancia de un amplificador	33
Figura 23. Espectro del ancho de banda en una señal digital periódica	34
Figura 24. (a) Una señal binaria y sus amplitudes de raíz cuadrada media de Fourier. (b) – (e) Aproximaciones sucesivas a la señal original.	37
Figura 25. Necesidades de ancho de banda de las aplicaciones.	40
Figura 26. Circuito amplificador y circuito atenuador	42
Figura 27. Bandas distribuidas a servicios publico	46
Figura 28. Bandas de frecuencia	48
Figura 29. Etapas de gestión y planificación del espectro radioeléctrico	49
Figura 30. Calidad de la banda ancha en América Latina y el Caribe	51
Figura 31. Modelo de solución	55
Figura 32. Eliminación de vacíos	57
Figura 33. Eliminación de redundantes	57
Figura 34. Gráfico de ruidos suaves	58
Figura 35. Transformación de datos	58
Figura 36. Prototipo de la red neurona	58

Figura 37. Gráfico de la técnica kfold	59
Figura 38. Estadísticas de tráfico de un (01) día.	60
Figura 39. Resumen de tráfico de ancho de banda de un (01) día.	60
Figura 40. Resumen de ancho de banda de un (01) mes.	61
Figura 41. Señal con ruido.	62
Figura 42. Aplicación de MAPE.	62
Figura 43. Proceso del cálculo del MAPE.	63
Figura 44. Modelo de red neuronal para minería de datos.	64
Figura 45. Idea del problema.	66
Figura 46. Diseño de red neuronal global.	74
Figura 47. Diseño de red neuronal detallada.	74
Figura 48. Entrenamiento 12 Iteraciones.	75
Figura 49. Evolución del error medio de 12 Iteraciones.	75
Figura 50. Regresión de la data de 12 Iteraciones.	76
Figura 51. Entrenamiento 8 Iteraciones.	77
Figura 52. Evolución del error medio de 8 iteraciones.	77
Figura 53. Regresión de la data de 8 iteraciones.	78
Figura 54. Entrenamiento 7 iteraciones.	79
Figura 55. Evolución del error medio de 7 iteraciones.	79
Figura 56. Predicción del consumo de ancho de banda de 7 iteraciones.	80
Figura 57. Predicción del consumo de ancho de banda de 9 rezagos.	80
Figura 58. Error de predicción con rezagos de 5 y 20 días.	81
Figura 59. Diseño de red neuronal.	82
Figura 60. Interface de entrenamiento.	82
Figura 61. Predicción de consumo de ancho de banda con ajuste de curva.	83
Figura 62. Error medio de predicción con ajuste de curva.	83
Figura 63. Interface de entrenamiento – Retropropagación.	84
Figura 64. Error medio de predicción con ajuste de curva.	84
Figura 65. Interface de entrenamiento – Retropropagación2.	85
Figura 66. Predicción de consumo de ancho de banda con ajuste de curva.	85
Figura 67. Error medio de predicción con retropropagación Bayesian Regularization.	87

Índice de tablas

Tabla 1. Descripción de Servidores de la UNAP	04
Tabla 2. Distribución de la Población de la UNAP	06
Tabla 3. Frecuencia de Uso del Software por parte de los Alumnos de la UNAP	06
Tabla 4. Beneficios del Software	07
Tabla 5. Problemas en el uso del Software	07
Tabla 6. Condición de las Labores Académicas	08
Tabla 7. Relación entre tasa de datos y armónicas	38
Tabla 8 Rangos de frecuencia del espectro y sus características principales	45
Tabla 9. Tabla de datos del software de monitoreo	61
Tabla 10. Valores Óptimos para Análisis de Resultados	64
Tabla 11. Matriz De Operacionalización	71
Tabla 12. Bandwitch febrero 2015	71
Tabla 13. Bandwitch Marzo 2015	72
Tabla 14. Bandwitch Abril 2015	72
Tabla 15. Bandwitch Total	73
Tabla 16.comparacion de resultados.	87

Capítulo 1

Introducción

1.1. Contexto

La Universidad Nacional de la Amazonía Peruana (UNAP) fue creada el 14 de enero de 1961 mediante Ley 13498 promulgada por el Gobierno de don Manuel Prado Ugarteche, como consecuencia a diversas acciones que la comunidad de Loreto venía efectuando desde la década de los 50 del siglo XX, con el propósito de contar con una institución de estudios superiores.

La UNAP en los actuales momentos se encuentra en proceso de adecuación institucional a la nueva Ley Universitaria 30220, tanto académica como administrativamente. Sobre esta base legal, el 15 de diciembre de 2014 mediante Resolución de Asamblea Estatutaria 001-2014-AE-UNAP, aprobó su nuevo estatuto. Asimismo, está sentando las bases para un programa de fortalecimiento para la calidad, al haber sido incluida por la mencionada Ley como referente por su antigüedad y situación geográfica, junto a otras once universidades públicas.

La Universidad Nacional de la Amazonía Peruana también está en la tarea de adaptación como respuesta a los requerimientos académicos, de investigación y sociales demandados por la región y el país. Actualmente, cuenta con más de 8 mil estudiantes en pregrado y postgrado, y más de seiscientos docentes. A través de sus catorce facultades ofrece treinta carreras de formación profesional y en su Escuela de Postgrado diversos programas de maestría y doctorado.

En Loreto, la UNAP es una institución educativa descentralizada. Su sede principal está ubicada en la ciudad de Iquitos, pero además, tiene escuelas en funcionamiento en las ciudades de Caballococha, Contamana, Nauta, Orellana, Requena, Yurimaguas y San Lorenzo.¹

Con Resolución de Asamblea Estatutaria 001-2014-AE-UNAP del 15 de diciembre de 2014 se aprobó el nuevo Estatuto de la UNAP de conformidad con la Ley 30220 (Ley Universitaria)². El Estatuto en su título VI, capítulo XXXIV establece la nueva estructura orgánica de la Universidad Nacional de la Amazonía Peruana que es la siguiente:

De la estructura orgánica

¹ <http://www.unapiquitos.edu.pe/unap/resena.html>

² <http://www.unapiquitos.edu.pe/unap/organigrama.html>

Artículo 95. La estructura orgánica de la Universidad Nacional de la Amazonía Peruana tiene como régimen académico a las Facultades, como órganos operativos, autónomos, descentralizados e integrados; su régimen administrativo cuenta con una estructura orgánica con funciones subordinadas al aspecto académico, de investigación y de promoción a la cultura; comprende:

1. Órganos de gobierno

- Asamblea Universitaria
- Consejo Universitario
- Consejos de Facultades

2. Órganos de alta Dirección

- Rectorado
- Vicerrectorados
- Decanatos

3. Órganos autónomos

- Comité Electoral Universitario
- Tribunal de Honor Universitario
- Defensoría Universitaria
- Comisión Permanente de Fiscalización.

4. Órganos de apoyo

- Secretaría General
- Dirección General de Administración
- Oficina Central de Ejecución Presupuestaria
- Oficina Central de Administración de Recursos Humanos
- Oficina Central de Ingeniería y Desarrollo de Infraestructura
- Oficina Central de Servicios Generales y Transporte
- Oficina Central de Producción de Bienes y Servicios
- Oficina General de Registro y Asuntos Académicos
- Oficina General de Investigación
- Oficina Central de Imagen Institucional, (Interinstitucionales, apoyo al becario)
- Oficina Central de Calidad Académica, Acreditación y Certificación
- Oficina General de Bienestar Universitario
- Oficina Central de Informática
- Biblioteca Central
- Oficina de Enlace

5. Órganos de Línea

- Facultades
- Agronomía
- Ciencias Biológicas
- Ciencias de la Educación y Humanidades
- Ciencias Económicas y de Negocios
- Ciencias Forestales
- Derecho y Ciencia Política
- Enfermería

- Farmacia y Bioquímica
- Industrias Alimentarias
- Ingeniería Química
- Ingeniería de Sistemas e Informática
- Medicina Humana
- Odontología
- Zootecnia
- Escuela de Postgrado.

6. Órganos de asesoramiento

- Oficina de Asesoría Jurídica
- Oficina General de Planificación

La UNAP cuenta con 21 locales interconectados por radio enlace y 6 locales por fibra óptica.³

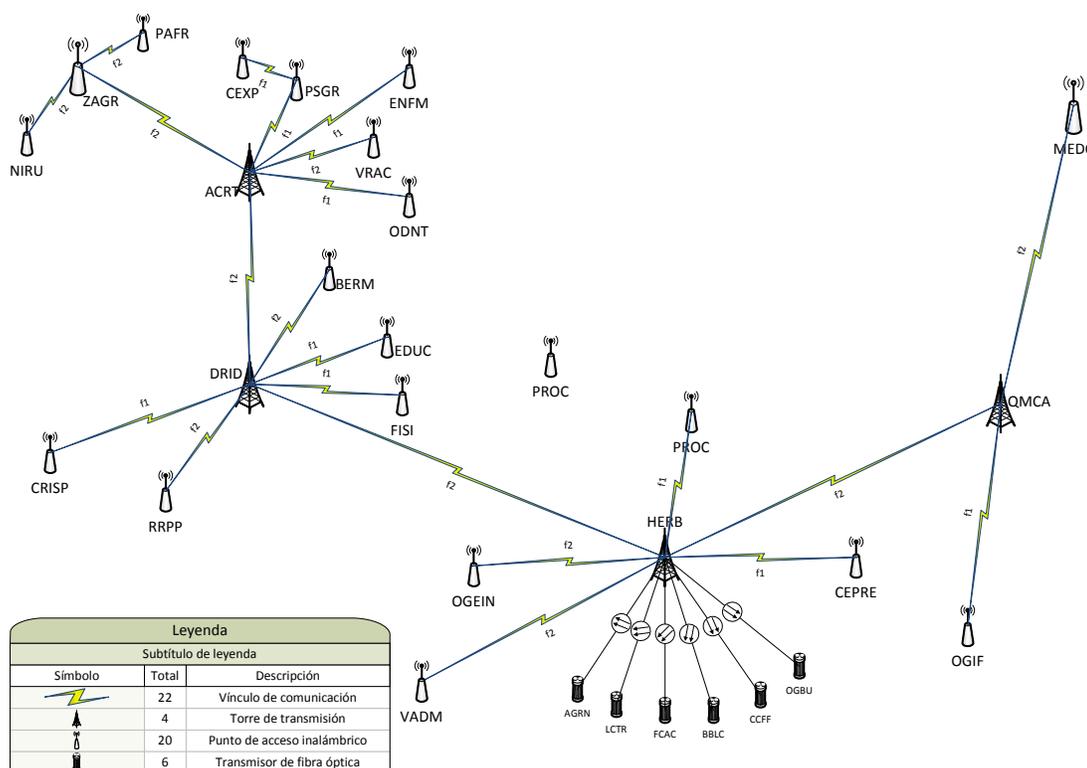
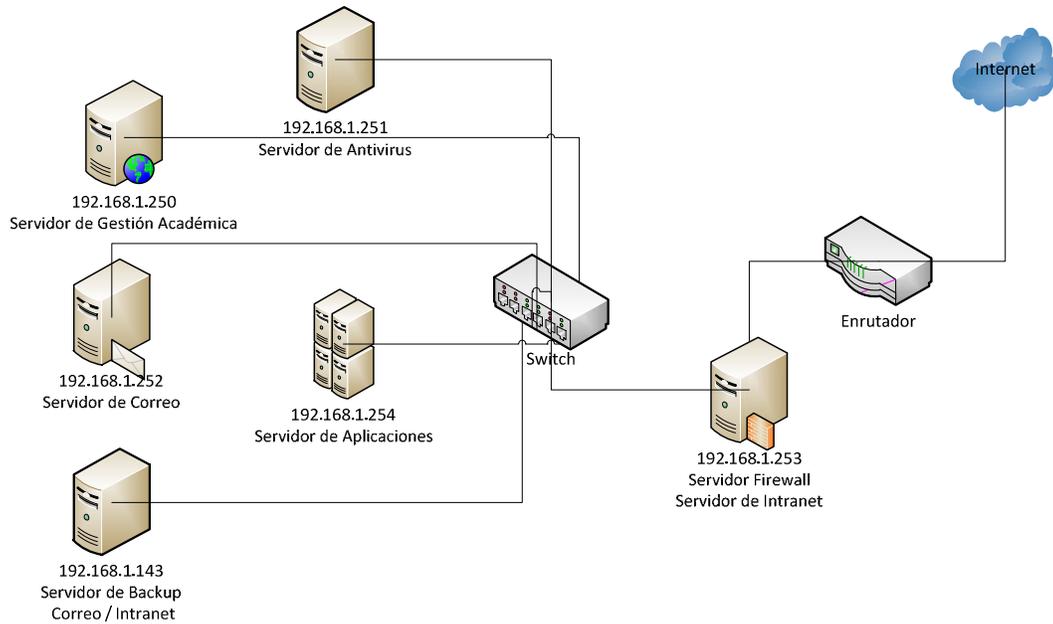


Figura 1. Estructura de Comunicaciones de la UNAP
 Fuente: Informe Técnico N° 001-2012-OGEIN-UNAP

Actualmente el centro de cómputo, cuenta con servidores, que brindan los diferentes servicios para el desarrollo de los procesos de gestión académica y administrativa en todo el campus universitario.

³ Informe Técnico N° 001-2012-OGEIN-UNAP



*Figura 2. Plataforma de Servidores de la UNAP
Fuente: Informe Técnico N° 001-2012-OGEIN-UNAP*

Servidor	Descripción
Servidor de Gestión Académica	▪ En este servidor funciona el Sistema de Gestión Académica, el cual se encuentra ejecutando el servicio de base de datos SQL Server 2000. Así como la Aplicación.
Servidor de Antivirus	▪ Este servidor funciona como repositorio de la base de datos del Antivirus ESNOD32. En él se realizan todas las actualizaciones para luego ser distribuidas a todas las computadoras del Campus.
Servidor de Correo	▪ En este servidor se encuentran alojada la base de datos de los correos del personal de la Universidad, con sistema operativo Linux Centos.
Servidor de Firewall Proxy / Intranet	▪ Servidor responsable de la seguridad de toda la red, a nivel de aplicaciones así como el acceso a internet.
Servidor de Aplicaciones	▪ Servidor que aloja las diferentes aplicaciones desarrolladas a medida por la UNAP, como por ejemplo el Aplicativo de Tramite Documentario, el Sistema de Grados y Títulos.
Servidor de Backups	▪ Servidor que será usado como respaldo de las diferentes aplicaciones y base de datos con los que cuenta la Universidad, como por el ejemplo el de Intranet usada por los docentes.

*Tabla 1. Descripción de Servidores de la UNAP
Fuente: Informe Técnico N° 001-2012-OGEIN-UNAP*

1.2. Antecedentes

La Universidad Nacional de la Amazonia Peruana UNAP es una institución de educación superior con una antigüedad de más de cincuenta años, desde su creación ha generado muchas expectativas debido a su ubicación geográfica y al impulso cultural y económico que pueda generar en su ámbito de acción.

La UNAP está ubicada en la ciudad de Iquitos en la Región Loreto con 368,852 kilómetros cuadrados en la selva amazónica peruana, que representa aproximadamente el 30% del territorio Nacional que posee límites internacionales con tres países: Brasil, Colombia y Ecuador.⁴

⁴ <http://www.unapiquitos.edu.pe/unap/influencia.html>

La ciudad de Iquitos se encuentra geográficamente aislada, no cuenta con carreteras de acceso, y está rodeada de ríos que son sus principales afluentes para el comercio y las comunicaciones junto con los medio aéreos; esta situación de aislamiento ha hecho que los servicios públicos como la electricidad y las comunicaciones sean costosas y limitadas, esta región no cuenta con acceso al Interconectado Nacional que trae consigo una tarifa de electricidad muy baja y la Banda ancha de acceso a internet; las comunicaciones son muy costosas, el acceso a Internet solo es satelital y todo el espectro de comunicaciones de la región se encuentra saturado.

La UNAP contrata los servicios de Telefónica del Perú para su acceso a Internet, cuenta con dos nodos principales de comunicaciones de 2MB cada uno y con una pérdida en hora punta del 90% es decir de 10 a 1 debido a la sobreventa (overbooking); vale decir que el principal proveedor de comunicaciones del Perú solo nos asegura el 10% del servicio contratado. Asegurar un mayor porcentaje de este servicio sube sobremanera los costes.

Esta realidad hace que los sistemas informáticos con los que cuenta la UNAP; como los sistemas académicos y administrativos implementados con tecnología web se vuelvan lentos y no satisfagan los requerimientos de gestión de la parte académica (Docentes y Alumnos) y administrativa (administradores, jefes de personal, tesorería, etc.) respectivamente, lo que nos obliga a conocer la demanda real del espectro radio eléctrico de nuestros sistemas en un determinado periodo para poder satisfacerla.

Conociendo el ancho de banda requerido y el espacio de tiempo de ese requerimiento se puede solicitar servicio de Internet dedicado, con ancho de banda específico para un determinado periodo de tiempo; lo que minimizaría los costos por un servicio real con un 100 % de ancho de banda asegurado.

En otras palabras el mercado requiere un instrumento de medición que le permita conocer la necesidad real del espectro radio eléctrico y la demanda proyectada, para satisfacer la concurrencia de los usuarios de las aplicaciones Web para un determinado periodo.

1.3. Justificación

Con el término de la tesis pretendo validar las redes neuronales como instrumento eficiente alternativo de medición de la demanda de Internet en cualquier entorno o institución y en la parte práctica, aplicarlo en la UNAP para mejorar el servicio de Internet necesario para la ejecución de las aplicaciones académicas y administrativas basadas en tecnología Web y una razonable disminución en los costos por la contratación del servicio de Internet obteniendo contratos más específicos y por un determinado tiempo, con los proveedores de comunicaciones de la localidad

El aporte es un instrumento de medición para calcular la necesidad del ancho de banda actual y proyectada en un determinado tiempo, mediante la utilización del modelo de redes neuronales como instrumento de medición y proyección de la demanda de Internet.

Inicialmente este trabajo podría beneficiar a cualquier institución que requiera acceso a Internet para la ejecución de sus aplicaciones Web, ya que podrían determinar con exactitud el ancho de banda a contratar por un determinado tiempo y costo. Este mismo principio se pudiera aplicar a otros campos como la medición de la demanda del consumo de corriente eléctrica en una población en un determinado horizonte de tiempo; o la medición de la demanda de consumo de agua potable de una localidad en una determinada

fecha, se podría aplicar también como un método alternativo para determinar cualquier necesidad de medir una demanda cuantitativa.

1.4. Problemática

La UNAP carece de un instrumento de medición que le permita conocer las necesidades reales del espectro radioeléctrico para internet y la demanda proyectada para satisfacer la concurrencia de usuarios de las aplicaciones Web en un determinado periodo de tiempo.⁵

1.5. Características del Problema

- Insatisfacción por parte de los alumnos, docentes y personal administrativo; del servicio de internet contratado por la UNAP.
- Eficiencia de las prestaciones de las aplicaciones en entorno WEB (software) de la UNAP.

MUESTRA			
POBLACIÓN	Nº DE PERSONAS	POBLACIÓN ENCUESTADA	PORCENTAJE
Alumnos	6961	24	0.67
Trabajadores Administrativos	473	12	0.33
TOTAL	7434	36	1.00

Tabla 2. Distribución de la Población de la UNAP

Fuente: Estudio A Nivel De Perfil

Se tiene una población estudiantil de 6961 alumnos y 473 trabajadores administrativos, ante ello se determinó una muestra de 24 encuestas para los alumnos y 12 encuestas para el personal administrativo haciendo un total de 36 encuestas.

¿CON QUE FRECUENCIA UTILIZA EL SOFTWARE DE LA UNIVERSIDAD?		
RUBRO	Nº DE ENCUESTADOS	%
Una vez al día	4	0.17
Algunos días a la semana	10	0.42
Una vez a la semana	5	0.21
Una vez al mes	2	0.08
Menos de una vez	3	0.12
TOTAL	24	1.00

Tabla 3. Frecuencia de Uso del Software por parte de los Alumnos de la UNAP

Fuente: Estudio A Nivel De Perfil

De acuerdo a la encuesta realizada el 42% de la población estudiantil afirmó que hace uso algunos días de la semana de los servicios del Software de la universidad para el desarrollo de sus labores académicas, ya que principalmente los alumnos hacen uso del internet y computadoras tanto en la sala de cómputo como en la biblioteca, el 21% hace uso una vez a la semana debido a que no cuentan maquinas personales y necesariamente hacen uso de la sala de cómputo y biblioteca para realizar sus labores académicas, con respecto al 12% de la población estudiantil que hace uso menos de una vez del servicio.

Los servicios que brinda el Software de la UNAP satisface parcialmente sus necesidades; la frecuencia de uso de los servicios del Software de menor incidencia es de una vez al mes, que representa el 8% ya que los alumnos después de hacer uso de la sala de computo en horas de prácticas de clases programadas, también hacen uso de otras máquinas y

⁵ (Estudio A Nivel De Perfil: Mejoramiento Informático En Gestión Académica E Investigación En La Universidad Nacional De La Amazonia Peruana, Distrito Iquitos, Provincia De Maynas, Región Loreto)

servicio de internet particular, finalmente de la misma forma la población que hace uso de una vez al día representa el 17%.

¿Con que frecuencia utiliza el Software de la UNAP?



Figura 3. Frecuencia que se utiliza el Software de la UNAP

Fuente: Estudio A Nivel De Perfil

CREE UD. QUE AL HACER USO DE LOS SERVICIOS DEL SOFTWARE RECIBE LOS BENEFICIOS DE:		
RUBRO	Nº DE ENCUESTADOS	%
Seguridad	4	17
Confianza	3	12
Disponibilidad	6	25
Velocidad	0	0
Bajos Costos	7	29
Ninguna	4	17
TOTAL	24	100

Tabla 4. Beneficios del Software

Fuente: Estudio A Nivel De Perfil

El 17% de la población de alumnos considera que al hacer uso de los servicios del Software recibe beneficios de seguridad, confiabilidad 12%, disponibilidad 25%, a excepción de velocidad que no representa un beneficio al usuario, debido a la poca capacidad ya que existe saturación en la demanda y limitada capacidad del ancho banda, esto degrada la velocidad de acceso a internet y rendimiento de la red corporativa y el 17% opino que no recibe ningún beneficio esto debido que no cubre sus expectativas de demanda.

Beneficios al hacer uso del Software

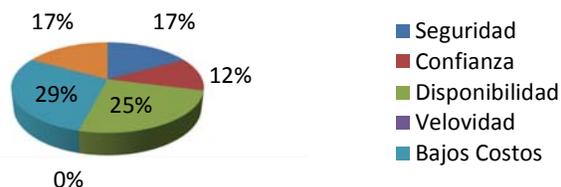


Figura 4. Beneficios al hacer uso del Software

Fuente: Estudio A Nivel De Perfil

¿QUÉ TIPO DE PROBLEMAS HA TENIDO EN EL USO DE PROGRAMAS?		
RUBRO	Nº DE ENCUESTADOS	%
Virus	11	46
Capacidad del PC (lento)	7	29
Conectividad a la Red Interna	3	13
Acceso a Internet	2	8
No estoy Seguro que Problemas he tenido	1	4
TOTAL	24	100

Tabla 5. Problemas en el uso del Software

Fuente: Estudio A Nivel De Perfil

El 46% considero que el problema de mayor incidencia en el uso de programas son los virus informáticos ya que limita la operatividad de los equipos asimismo altera el contenido de la información y riesgo de pérdida de la misma, esto a la vez imposibilita el incumplimiento de sus objetivos académicos, el 29% opinó, tanto en capacidad de la PC

(lento), un 3% tienen problema con respecto a la conectividad a la red interna ha tenido problemas en el uso de programas, esto es debido a que no se realiza mantenimiento tanto físico como de programación o la existencia de configuraciones con error que ralentiza el ordenador y pierde el rendimiento, el 2% opino que el acceso al internet ha sido el problema de mayor frecuencia en el uso de sus programas como ya se mencionó anteriormente se debe a que el ancho de banda es insuficiente para la creciente demanda y ninguno considera que no está seguro que problemas ha tenido y un 1% no está seguro que problemas a tenido.

¿Qué tipo de problema ha tenido en el uso de programas?

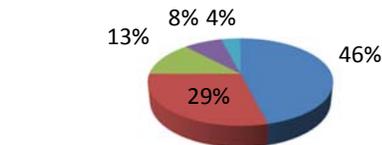
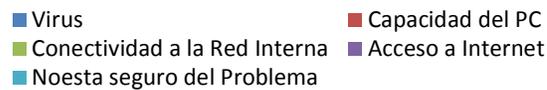


Figura 5. Problemas en el Uso de Programa

Fuente: Estudio A Nivel De Perfil

¿SUS LABORES ACADÉMICAS ESTÁN CONDICIONADAS AL ACCESO A INTERNET?		
RUBRO	Nº DE ENCUESTADOS	%
Si	22	92
No	2	8
TOTAL	24	100

Tabla 6. Condición de las Labores Académicas

Fuente: Estudio A Nivel De Perfil

El 92% considera que sus labores está condicionada al acceso a internet ya que este servicio ha cambiado los métodos de investigación y de recolección de datos además la rapidez con que se puede encontrar la información; la gran cantidad de datos que se pueden conseguir acerca de un mismo tema de interés; el bajo costo que significa el no tener que comprar determinado libro; etc. Por otro lado el 8% consideran que esta nueva modalidad de procesar información es perjudicial para el aprendizaje, pues se les hace muy fácil copiar monografías enteras, donde todo está hecho y sólo tienen que hacer pocas modificaciones.

¿Sus labores académicas esta condicionado al acceso de internet



Figura 6. Labores académicas Condicionadas a Internet

Fuente: Estudio A Nivel De Perfil

Capítulo 2

Objetivo, hipótesis, alcance

2.1. Objetivo General

Brindar a la Universidad Nacional de la Amazonía Peruana (UNAP) un instrumento que permita conocer las necesidades reales del espectro radioeléctrico para internet y la demanda proyectada para satisfacer la concurrencia de usuarios de las aplicaciones Web en un determinado periodo de tiempo; basado en un modelo de Red Neuronal con menor índice de MAPE.

2.2. Objetivos Específicos

- a) Demostrar que el modelo de Levenberg-Marquardt tiene menor MAPE que el modelo de Retropropagación en el consumo de ancho de banda de internet en la UNAP.
- b) Limpiar y seleccionar la base de datos.
- c) Recolectar datos históricos del consumo del ancho de banda.
- d) Realizar una exploración de los datos recolectados, detectando y corrigiendo anomalías en la data recolectada (valores extremos, ruidosos, inconsistentes).
- e) Construir modelos basados en dos técnicas de minería de datos: Redes neuronales del tipo Retropropagación y Levenberg-Marquardt.
- f) Entrenar y ajustar los parámetros de cada red neuronal.
- g) Hallar los valores de las medidas de desempeño para ambos modelos y compararlos mediante una prueba de hipótesis.

2.3. Hipótesis

El modelo de red neuronal con algoritmo de aprendizaje Levenberg-Marquardt es el instrumento apropiado para el pronóstico de ancho de banda de internet por tener un menor porcentaje de error (MAPE) que el modelo de red Neuronal con algoritmo de aprendizaje de Retropropagación.

- **Variable Independiente:** Modelo de red neuronal
- **Variable dependiente:** Consumo de ancho de banda (MAPE)

Indicadores Variable Independiente: Los siguientes son los indicadores de la variable independiente:

Algoritmo de Entrenamiento: Tipo de algoritmo de entrenamiento de las redes neuronales que se aplicara en el experimento para conocer el comportamiento de la variable dependiente, las cuales serán el algoritmo de Retropropagación y el algoritmo de Levenberg-Marquardt

Números de Neuronas de la Capa Intermedia (Ci): Se refiere a la cantidad de neuronas que estarán en la capa oculta lo cual nos servirá para poder obtener relaciones no lineales.

Número de Iteraciones (I): Los números de veces que realizaremos el aprendizaje de la red el cual dependerá del tipo de red que utilizaremos.

Número de Observaciones para la predicción (N): Representa la cantidad de observaciones tomadas para realizar la predicción.

Porcentaje de la muestra de entrenamiento (h): Representa el porcentaje para determinar la cantidad de registros para el proceso de entrenamiento y pruebas de la red neuronal.

Índices de Variable Independiente

Algoritmo de Entrenamiento: Categoría asignada al algoritmo de entrenamiento a usar en el experimento, el cual tendrá los valores de resultado ejecutados en los algoritmos de Retropropagación y el Algoritmo de Levenberg-Marquardt.

Números de Neuronas de la Capa Intermedia (Ci): Categoría asignada al número de neuronas.

Número de Iteraciones (I): Categoría asignada al número de iteraciones para cada red neuronal.

Número de Observaciones para la predicción (N): Categoría asignada al número de observaciones para la predicción.

Porcentaje de la muestra de entrenamiento (h): Categoría asignada al porcentaje.

Indicadores Variable Dependiente

Porcentaje de Error Absoluto (MAPE): El objetivo es pronosticar el consumo de ancho de banda con un mínimo MAPE para cada técnica de red neuronal aplicada al experimento.

Índices de Variable Dependiente

Porcentaje de Error Absoluto (MAPE): Categoría asignada a porcentaje de error absoluto la cual se expresa en unidades.

2.4. Alcance del Proyecto

El alcance del proyecto consiste en reconocer un modelo de red neuronal con menor MAPE para el pronóstico y optimización del ancho de banda de internet y la demanda proyectada para satisfacer la concurrencia de usuarios de las aplicaciones Web en un determinado periodo de tiempo en todo el ámbito del alcance de la UNAP.

Capítulo 3

Estado del arte

3.1. Redes Neuronales

"Una red neuronal es un sistema compuesto de muchos elementos procesadores simples operando en paralelo, cuya función es determinada por la estructura de la red, fuerza en las conexiones y el procesamiento realizado por los elementos computacionales en los nodos."⁶

Datos Históricos

En 1936 - Alan Turing. Fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación. Sin embargo, los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes, en 1943, lanzaron una teoría acerca de la forma de trabajar de las neuronas (Un Cálculo Lógico de la Inminente Idea de la Actividad Nerviosa - Boletín de Matemática Biofísica 5: 115-133). Ellos modelaron una red neuronal simple mediante circuitos eléctricos.

En 1949 - Donald Hebb. Fue el primero en explicar los procesos del aprendizaje (que es el elemento básico de la inteligencia humana) desde un punto de vista psicológico, desarrollando una regla de como el aprendizaje ocurría. Aun hoy, este es el fundamento de la mayoría de las funciones de aprendizaje que pueden hallarse en una red neuronal. Su idea fue que el aprendizaje ocurría cuando ciertos cambios en una neurona eran activados. También intentó encontrar semejanzas entre el aprendizaje y la actividad nerviosa. Los trabajos de Hebb formaron las bases de la Teoría de las Redes Neuronales.

En 1950 - Karl Lashley. En sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro sino que era distribuida encima de él.

En 1956 - Congreso de Dartmouth. Este Congreso frecuentemente se menciona para indicar el nacimiento de la inteligencia artificial.

En 1957 - Frank Rosenblatt. Comenzó el desarrollo del Perceptron. Esta es la red neuronal más antigua; utilizándose hoy en día para aplicación como identificador de patrones. Este modelo era capaz de generalizar, es decir, después de haber aprendido una serie de patrones podía reconocer otros similares, aunque no se le hubiesen presentado en el entrenamiento. Sin embargo, tenía una serie de limitaciones, por ejemplo, su incapacidad para resolver el problema de la función OR-exclusiva y, en general, era incapaz de clasificar clases no separables linealmente.

⁶ Estudio de Redes Neuronales de DARPA (1988, AFCEA International Press, p. 60)

En 1959 - Frank Rosenblatt: Principios de Neurodinámica. En este libro confirmó que, bajo ciertas condiciones, el aprendizaje del Perceptron convergía hacia un estado finito (Teorema de Convergencia del Perceptron).

En 1960 - Bernard Widroff/Marcian Hoff. Desarrollaron el modelo Adaline (ADAPtative LINear Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros adaptativos para eliminar ecos en las líneas telefónicas) que se ha utilizado comercialmente durante varias décadas.

En 1961 - Karl Steinbeck: Die Lernmatrix. Red neuronal para simples realizaciones técnicas (memoria asociativa).

En 1969 - Marvin Minsky/Seymour Papert. En este año casi se produjo la “muerte abrupta” de las Redes Neuronales; ya que Minsky y Papert probaron (matemáticamente) que el Perceptron no era capaz de resolver problemas relativamente fáciles, tales como el aprendizaje de una función no-lineal. Esto demostró que el Perceptron era muy débil, dado que las funciones no-lineales son extensamente empleadas en computación y en los problemas del mundo real.

En 1974 - Paul Werbos. Desarrolló la idea básica del algoritmo de aprendizaje de propagación hacia atrás (backpropagation); cuyo significado quedó definitivamente aclarado en 1985.

En 1977 - Stephen Grossberg: Teoría de Resonancia Adaptada (TRA). La Teoría de Resonancia Adaptada es una arquitectura de red que se diferencia de todas las demás previamente inventadas. La misma simula otras habilidades del cerebro: memoria a largo y corto plazo.

En 1985 - John Hopfield. Provocó el renacimiento de las redes neuronales con su libro: “Computación neuronal de decisiones en problemas de optimización.”

En 1986 - David Rumelhart/G. Hinton. Redescubrieron el algoritmo de aprendizaje de propagación hacia atrás (backpropagation).

A partir de 1986, el panorama fue alentador con respecto a las investigaciones y el desarrollo de las redes neuronales. En la actualidad, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen (sobre todo en el área de control) y las empresas que lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación).

Así mismo podemos afirmar que son muchas las formas de definir a las redes neuronales, como por ejemplo tenemos:

- Una nueva forma de computación, inspirada en modelos biológicos.
- Un modelo matemático compuesto por un gran número de elementos procesales organizados en niveles.
- Un sistema de computación compuesto por un gran número de elementos simples, elementos de procesos muy interconectados, los cuales procesan

información por medio de su estado dinámico como respuesta a entradas externas.

Una red neuronal o red neural simplemente, puede referirse a:

- **Red neuronal biológica**, cúmulo de neuronas físicamente interconectadas cuya actividad ayuda a definir un circuito reconocible en el sistema nervioso.
- Modelo biológico*

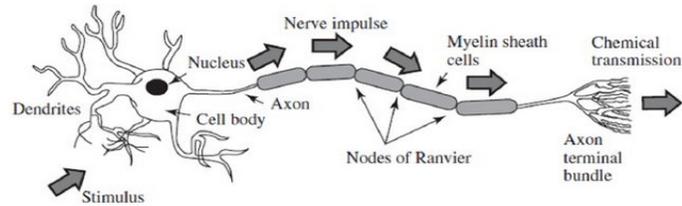


Figura 7. Modelo Biológico de una Neurona

Fuente: Internet

- **Red neuronal artificial**, modelos matemáticos, computacionales, artificiales, ideales de una red neuronal empleados en estadística, psicología cognitiva, e inteligencia artificial.

- Modelo Artificial† (Perceptrón)

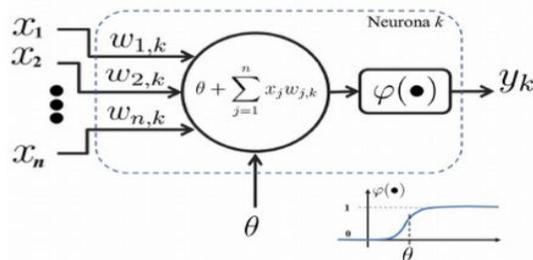


Figura .8. Modelo Artificial de una Neurona

Fuente: Internet

Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas se incluyen:

- Aprendizaje Adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.
- Auto-organización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.

- Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.
- Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

Las redes neuronales RN se utilizan para aprender patrones y relaciones de datos. tradicionalmente, un programador o un analista especifican códigos de cada faceta del problema, en orden para que la computadora pueda entender la situación. Las RN no requieren el código explícito del problema. Por ejemplo, para generar un modelo que lleve a cabo un pronóstico de ventas, las RN solo necesitan datos, relacionados con el problema.

Esta característica se debe al desarrollo de algoritmos de aprendizaje, mediante el cual las RN aprenden las relaciones de los datos. Los algoritmos de aprendizaje habilitan a la RN para adquirir conocimiento desde datos disponibles y aplicar ese conocimiento.

El estudio de las redes neuronales artificiales RNA o ANS (Artificial Neural Systems) puede orientarse en dos direcciones, bien como modelos del sistema nervioso y los fenómenos cognitivos, o bien como herramientas para la resolución de problemas prácticos. En este sentido, consideraremos que las redes neuronales artificiales son sistemas, hardware o software, de procesamiento, que copian esquemáticamente la estructura neuronal del cerebro para tratar de reproducir sus capacidades.

Las RNA o ANS son capaces de aprender de la experiencia a partir de las señales o datos provenientes del exterior, dentro de un marco de computación paralela y distribuida, fácilmente implementable en dispositivos hardware específicos.



Figura 9. Modelo Neuronal

Fuente: Internet

Desde un punto de vista funcional, las neuronas constituyen procesadores de información sencillos. Como todo sistema de este tipo, poseen un canal de entrada de información, las

dendritas, un órgano de cómputo, el soma, y un canal de salida, el axón. En las interneuronas el axón envía la información a otras neuronas, mientras que en las neuronas motoras lo hace directamente al músculo. Existe un tercer tipo de neuronas, las receptoras o sensoras, que en vez de recibir la información de otras neuronas, la reciben directamente del exterior (tal sucede, por ejemplo, en los conos y bastones de la retina). Se calcula que una neurona del córtex cerebral recibe información, por término medio, de unas 10,000 neuronas (convergencia), y envía impulsos a varios cientos de ellas (divergencia).

En el córtex se aprecia la existencia de una organización horizontal en capas (se suelen señalar unas seis capas), coexistiendo una organización vertical en forma de columnas de neuronas. Hay grupos neuronales, compuestos por millones de neuronas pertenecientes a una determinada región del cerebro, que constituyen unidades funcionales especializadas en ciertas tareas (por ejemplo, existe un área visual, un área auditiva, un córtex sensorio-motor, etc.); todos los subsistemas juntos conforman el encéfalo. Se tiene evidencia de que el procesamiento en el sistema nervioso involucra la actuación de muchos de tales subsistemas, que intercambian continuamente información.

Generación y Transmisión de la Señal Nerviosa

La unión entre dos neuronas se denomina sinapsis. En el tipo de sinapsis más común no existe un contacto físico entre las neuronas, sino que éstas permanecen separadas por un pequeño vacío de unas 0.2 micras. En relación a la sinapsis, se habla de neuronas presinápticas (las que envían las señales) y postsinápticas (las que las reciben). Las sinapsis son direccionales, es decir, la información fluye siempre en un único sentido.

Las señales nerviosas se pueden transmitir eléctrica o químicamente. La transmisión química prevalece fuera de la neurona, mientras que la eléctrica lo hace en el interior. La transmisión química se basa en el intercambio de neurotransmisores, mientras que la eléctrica hace uso de descargas que se producen en el cuerpo celular, y se propagan por el axón.

El fenómeno de la generación de la señal nerviosa está determinado por la membrana neuronal y los iones presentes a ambos lados de ella. La membrana se comporta como un condensador, que se carga al recibir corrientes debidas a las especies iónicas presentes. La membrana contiene canales iónicos selectivos al tipo de ión, algunos son pasivos (consisten en simples poros de la membrana) y otros activos (poros que solo se abren ante ciertas circunstancias). En esencia, las especies iónicas más importantes, que determinan buena parte de la generación y propagación del impulso nervioso, son Na^+ , K^+ y Ca^{2+} , además de los iones de proteínas, que denotaremos genéricamente por P^{2-} , y que se originan por pérdidas de los anteriores.

En estado de reposo el protoplasma del interior de la neurona permanece cargado negativamente en relación al medio externo, existiendo entre ambos una diferencia de potencial de unos -60 mV. La existencia de este potencial de reposo se debe a las concentraciones de Na^+ , K^+ y P^{2-} , y se mantiene mediante el flujo de iones Na^+ y K^+ a través de la membrana. El interior de la neurona está cargado negativamente puesto que, debido a su gran tamaño, los iones P^{2-} quedan dentro, al no poder atravesar la membrana. Los canales de K^+ son pasivos, y se comportan como simples poros. Por su parte, los de Na^+ son activos, y se convierten en permeables a este ión cuando el potencial del soma desciende por debajo de unos -45 mV. Por ello, en condiciones de reposo, la membrana es permeable al K^+ , pero no al Na^+ , y sus concentraciones se generan y mantienen por la

acción de la denominada bomba de $\text{Na}^+\text{-K}^+$, que por cada dos iones K^+ que introduce extrae 3 iones Na^+ al exterior. Este bombeo de iones se realiza a costa de un gasto de energía, de ahí que la neurona sea una célula de alto consumo energético. El resultado final es que la concentración de K^+ y de P^{2-} es alta en su interior, y la de Na^+ lo es en el exterior, siendo la diferencia de potencial debida a sus concentraciones de unos -60 mV .

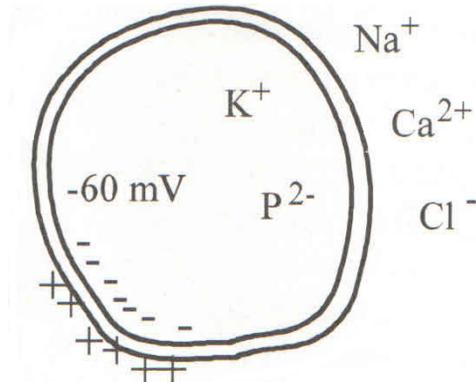


Figura 10. Iones en la neurona dentro y fuera de la membrana celular.

Fuente: Internet

La forma de comunicación más habitual entre dos neuronas es de tipo químico. La neurona presináptica libera unas sustancias químicas complejas denominadas neurotransmisores (como el glutamato o la adrenalina), que atraviesan el vacío sináptico. Si la neurona postsináptica posee en las dendritas o en el soma canales sensibles a los neurotransmisores liberados, los fijarán, y como consecuencia de ello permitirán el paso de determinados iones a través de la membrana.

Las corrientes iónicas que de esta manera se crean provocan pequeños potenciales postsinápticos, excitadores (positivos) o inhibidores (negativos), que se integrarán en el soma, tanto espacial como temporalmente; éste es el origen de la existencia de sinapsis excitatorias y de sinapsis inhibitorias.

Si se ha producido un suficiente número de excitaciones, la suma de los potenciales positivos generados puede elevar el potencial de la neurona por encima de los -45 mV (umbral de disparo): en ese momento se abren bruscamente los canales de sodio, de modo que los iones Na^+ , cuya concentración en el exterior es alta, entran masivamente al interior, provocando la despolarización brusca de la neurona, que pasa de un potencial de reposo de -60 mV a unos $+50\text{ mV}$.

A continuación la neurona vuelve a la situación original de reposo de -60 mV ; este proceso constituye la generación de un potencial de acción, que al propagarse a lo largo del axón da lugar a la transmisión eléctrica de la señal nerviosa. Tras haber sido provocado un potencial de acción, la neurona sufre un período refractario, durante el cual no puede generarse uno nuevo.

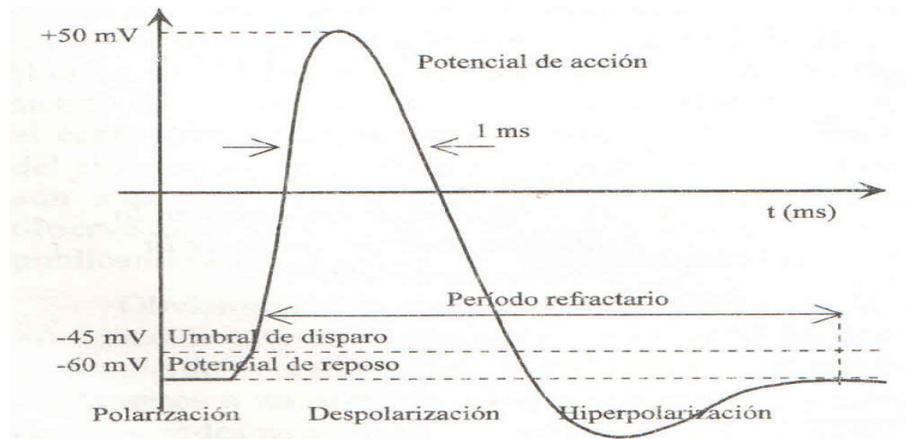


Figura 11. Potencial de Acción
Fuente: Internet

Un hecho importante es que el pulso así generado es "digital", en el sentido de que existe o no existe pulso, y todos ellos son de la misma magnitud. Por otra parte, ante una estimulación más intensa disminuye el intervalo entre pulsos, por lo que la neurona se disparará a mayor frecuencia cuanto mayor sea el nivel de excitación. Es decir, la excitación queda codificada en la frecuencia de los pulsos producidos. Por otra parte, la frecuencia de disparo de la neurona no puede crecer indefinidamente, sino que existe una frecuencia máxima de respuesta debida a la existencia del período refractario. En resumen, ante un estímulo mayor la frecuencia de respuesta aumenta, hasta que se alcanza una saturación conforme nos acercamos a la frecuencia máxima. De este modo, la función de respuesta de la neurona, frecuencia de disparo frente a intensidad de estimulación, tiene el aspecto mostrado en la Figura 12, que se emulará en muchos de los modelos de neurona artificial. La frecuencia de disparo oscila habitualmente entre 1 y 100 pulsos por segundo, aunque algunas neuronas pueden llegar a los 500 durante pequeños periodos de tiempo.

Por otra parte, no todas las neuronas se disparan generando un tren de pulsos de una frecuencia aproximadamente constante, pues la presencia de otras especies iónicas hace que diferentes tipos de neuronas posean patrones de disparo distintos, en forma de trenes puros, paquetes de pulsos, o presentando patrones más complejos.

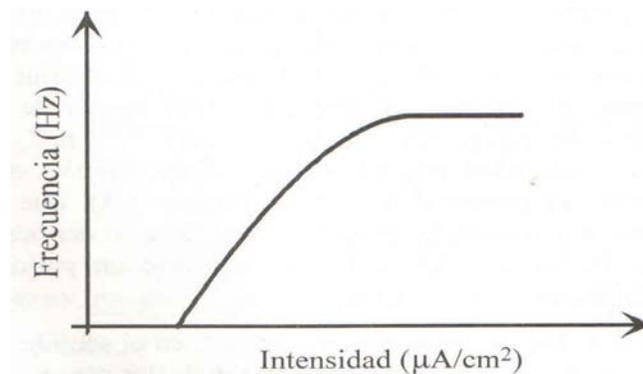


Figura 12. Función de respuesta de la neurona biológica ante estímulos del exterior.
Fuente: Internet

Generado un pulso eléctrico por el soma, el transporte activo que se produce a lo largo del axón permite que pueda transmitirse a grandes distancias (hasta un metro) sin degradarse. En los extremos del axón existen unas pequeñas vesículas sinápticas que almacenan paquetes de neurotransmisores; así, ante la aparición de un pulso eléctrico proveniente del cuerpo celular, y por mediación de los iones Ca^{2+} , se produce la liberación de neurotransmisores en cantidades cuantificadas (correspondientes a un número entero de vesículas). El número de pulsos que llegan y su frecuencia determinan la cantidad de neurotransmisor liberado, que a su vez producirá nuevas excitaciones o inhibiciones en otras neuronas.



Figura 13. Patrones de disparo: a) regular, b) en paquete de pulsos en una neurona piramidal del córtex, c) disparo de una célula de Purkinje del cerebro
Fuente: Internet

El mecanismo aquí descrito constituye la forma más común de transmisión de la señal nerviosa, pero no el único. Cuando la distancia que debe recorrer la señal es menor de 1 mm la neurona puede no codificarla en frecuencia, sino enviar una señal puramente analógica. Es decir, la evolución biológica encontró que a distancias cortas la señal no se degrada sustancialmente, por lo que podía enviarse tal cual, mientras que a distancias largas era preciso codificarla para evitar su degradación y la consiguiente pérdida de información. La naturaleza descubrió que la codificación en forma de frecuencia de pulsos digitales proporcionaba calidad, seguridad y simplicidad en la transmisión.

Aprendizaje

La intensidad de una sinapsis no viene representada por una cantidad fija, sino que puede ser modulada en una escala temporal mucho más amplia que la del disparo de las neuronas (horas, días o meses). Esta plasticidad sináptica se supone que constituye, al menos en buena medida, el aprendizaje tal y como postuló, encontrándose posteriormente evidencias experimentales de ello.

Durante el desarrollo de un ser vivo, el cerebro se modela, de forma que existen muchas cualidades del individuo que no son innatas, sino que se adquieren por la influencia de la información que del medio externo proporciona sus sensores. Existen diferentes formas de modelar el sistema nervioso: por el establecimiento de nuevas conexiones, ruptura de otras, modelado de las intensidades sinápticas (plasticidad) o incluso mediante muerte neuronal. Este tipo de acciones (en especial la modificación de las intensidades sinápticas) serán las que utilicen los sistemas neuronales artificiales para llevar a cabo el aprendizaje.

Mecanismos de aprendizaje.

Se ha visto que los datos de entrada se procesan a través de la red neuronal con el propósito de lograr una salida. Una red neuronal debe aprender a calcular la salida correcta para cada constelación (arreglo o vector) de entrada en el conjunto de ejemplos. Este proceso de aprendizaje se denomina: proceso **de entrenamiento o acondicionamiento**. El conjunto de datos (o conjunto de ejemplos) sobre el cual este proceso se basa es, por ende, llamado: **conjunto de datos de entrenamiento**.

Si la topología de la red y las diferentes funciones de cada neurona (entrada, activación y salida) no pueden cambiar durante el aprendizaje, mientras que los pesos sobre cada una de las conexiones si pueden hacerlo; el aprendizaje de una red neuronal significa: **adaptación de los pesos**.

En otras palabras el aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el mismo se reducen a la destrucción, modificación y creación de conexiones entre las neuronas. En los sistemas biológicos existe una continua destrucción y creación de conexiones entre las neuronas. En los modelos de redes neuronales artificiales, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero. De la misma manera, una conexión se destruye cuando su peso pasa a ser cero.

Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren modificaciones, por lo tanto, se puede afirmar que este proceso ha terminado (la red ha aprendido) cuando los valores de los pesos permanecen estables ($dw_{ij}/dt = 0$).

Un aspecto importante respecto al aprendizaje de las redes neuronales es el conocer cómo se modifican los valores de los pesos, es decir, cuáles son los criterios que se siguen para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información.

Hay dos métodos de aprendizaje importantes que pueden distinguirse:

- Aprendizaje supervisado.
- Aprendizaje no supervisado.

Otro criterio que se puede utilizar para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual o si el aprendizaje supone la desconexión de la red, es decir, su inhabilitación hasta que el proceso termine. En el primer caso, se trataría de un aprendizaje **on line**, mientras que el segundo es lo que se conoce como **off line**.

Cuando el aprendizaje es off line, se distingue entre una **fase de aprendizaje o entrenamiento** y una **fase de operación o funcionamiento**, existiendo un conjunto de datos de entrenamiento y un conjunto de datos de test o prueba, que serán utilizados en la correspondiente fase. Además, los pesos de las conexiones permanecen fijos después que termina la etapa de entrenamiento de la red. Debido precisamente a su carácter estático, estos sistemas no presentan problemas de estabilidad en su funcionamiento.

Una generalización de la fórmula o regla para decir los cambios en los pesos es la siguiente:

$$\text{Peso Nuevo} = \text{Peso Viejo} + \text{Cambio de Peso}$$

Modelo General de Neurona Artificial

En este punto describiremos la estructura genérica de neurona artificial en el marco establecido por el grupo PDP.

Se denomina **procesador elemental o neurona** a un dispositivo simple de cálculo que, a partir de un vector de entrada procedente del exterior o de otras neuronas, proporciona una única respuesta o salida. Los elementos que constituyen la neurona de etiqueta i son los siguientes.

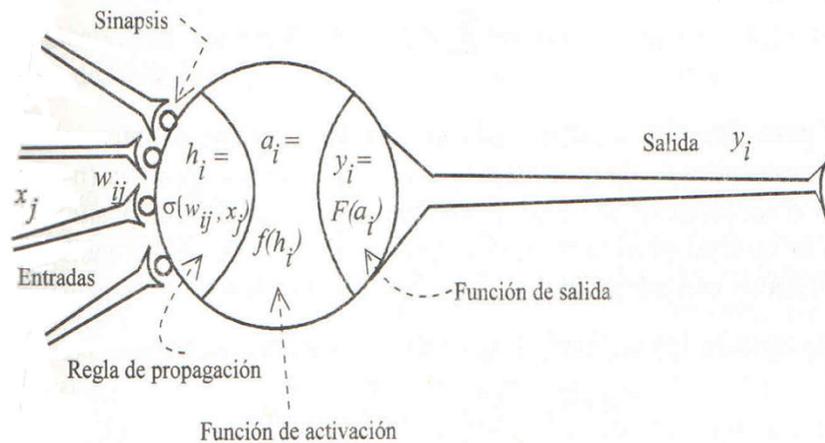


Figura 14 Modelo Genérico de neurona Artificial

Fuente: Internet

- Conjunto de **entradas**, $x_j(t)$.
- **Pesos Sinápticos** de la neurona i , W_{ij} que representan la intensidad de interacción entre cada neurona presináptica j y la neurona postsináptica i .
- **Regla de Propagación** $\sigma(W_{ij}, X_j(t))$, que proporciona el valor del potencial postsináptico $h_i(t) = \sigma(W_{ij}, X_j(t))$, de la neurona i en función de sus pesos y entradas.
- **Función de Activación** $f_i(a_i(t-1), h_i(t))$, que proporciona el estado de activación actual $a_i(t) = f_i(a_i(t-1), h_i(t))$ de la neurona i , en función de su estado anterior $a_i(t-1)$ y de su potencial postsináptico actual.
- **Función de Salida** $F_i(a_i(t))$, que proporciona la salida actual $y_i(t) = F_i(a_i(t))$ de la neurona i en función de su estado de activación.

De este modo, la operación de la neurona i puede expresarse como:

$$y_i(t) = F_i(f_i([a_i(t-1), \sigma(W_{ij}, X_j(t))])) \quad (\text{Ecuación 3.1})$$

Este modelo de neurona formal se inspira en la operación de la biológica, en el sentido de integrar una serie de entradas y proporcionar cierta respuesta, que se propaga por el axón.

Modelo estándar de Neurona Artificial

El modelo de neurona expuesto en la sección anterior resulta muy general. En la práctica suele utilizarse uno más simple, que denominaremos **neurona estándar**, que

constituye un caso particular del modelo del PDP, considerando que la regla de propagación, la neurona estándar consiste en:

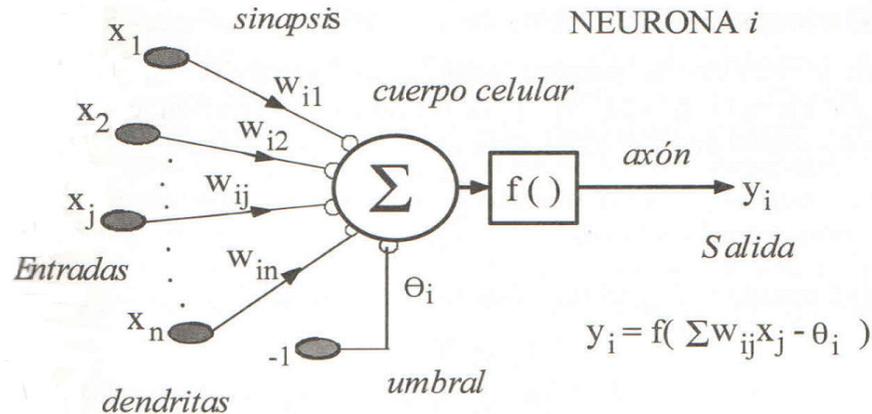


Figura 15 Modelo de Neurona Estándar⁷

Fuente: Internet

- Un conjunto de **entradas** $X_j(t)$ y pesos sinápticos W_{ij} .
- Una **regla de propagación** $h_i(t) = \sigma(W_{ij}, X_j(t))$; $h_i(t) = \sum_j W_{ij} X_j$ es la más común.
- Una **función de activación** $y_i(t) = f_i(h_i(t))$, que representa simultáneamente la salida de la neurona y su estado de activación.

Con frecuencia se añade al conjunto de pesos de la neurona un parámetro adicional θ_i , que denominaremos umbral i_2 , que se resta del potencial postsináptico, por lo que el argumento de la función de activación queda.

$$\sum_j W_{ij} X_j - \theta_i \quad (\text{Ecuación 3.2})$$

lo que representa añadir un grado de libertad adicional a la neurona. Veremos que en el caso de nodos de respuesta todo-nada este parámetro representará el umbral de disparo de la neurona, es decir, el nivel mínimo que debe alcanzar el potencial postsináptico (o potencial de membrana) para que la neurona se dispare o active.

En conclusión, el modelo de neurona que denominaremos estándar queda

$$y_i(t) = f_i \left(\sum_j W_{ij} X_j - \theta_i \right) \quad (\text{Ecuación 3.3})$$

Ahora bien, si hacemos que los índices i y j comiencen en 0, podemos definir $W_{i0} \equiv \theta_i$ y $X_0 \equiv -1$ (constante), con lo que el potencial postsináptico (potencial local, o de membrana) se obtiene realizando la suma desde $j = 0$.

$$y_i(t) = f_i \left(\sum_{j=0}^n W_{ij} X_j \right) \quad (\text{Ecuación 3.4})$$

⁷ <http://neo.lcc.uma.es/staff/francis/pdf/PFC-Chicano03.pdf>

Definida de esta manera la neurona estándar, basta con establecer la forma de la función de activación para determinarla por completo.

Arquitecturas de Redes Neuronales

Se denomina arquitectura a la topología, estructura o patrón de conexionado de una red neuronal. En un ANS los nodos se conectan por medio de sinapsis, esta estructura de conexiones sinápticas determina el comportamiento de la red. Las conexiones sinápticas son direccionales, es decir, la información solamente puede propagarse en un único sentido; desde la neurona presináptica a la postsináptica (Figura 16). En general, las neuronas se suelen agrupar en unidades estructurales que denominaremos capas. Las Neuronas de una capa pueden agruparse, a su vez, formando **grupos neuronales** (clusters). Dentro de un grupo, o de una capa si no existe este tipo de agrupación, las neuronas suelen ser del mismo tipo. Finalmente, el conjunto de una o más capas constituye la **red neuronal**.

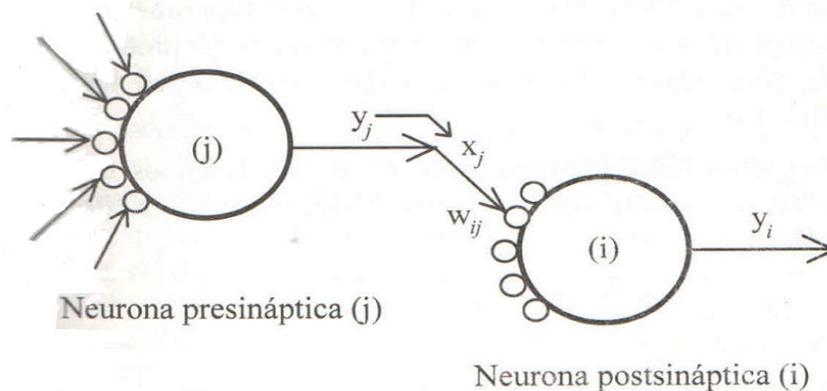


Figura 16. Interacción entre una neurona presináptica y otra postsináptica
Fuente: Internet

Se distinguen tres tipos de capas: de entrada, de salida y ocultas.

Una **capa de entrada** o sensorial está compuesta por neuronas que reciben datos o señales procedentes del entorno (por ejemplo, proporcionados por sensores).

Una **capa de salida** es aquella cuyas neuronas proporcionan la respuesta de la red neuronal (sus neuronas pueden estar conectadas a efectores).

Una **capa oculta** es aquella que no tiene una conexión directa con el entorno, es decir, que no se conecta directamente ni a órganos sensores ni a efectores. Este tipo de capa proporciona a la red neuronal grados de libertad adicionales, gracias a los cuales puede encontrar representaciones internas correspondientes a determinados rasgos del entorno, proporcionando una mayor riqueza computacional.

Las conexiones entre las neuronas pueden ser excitatorias o inhibitorias: un peso sináptico negativo define una **conexión inhibitoria**, mientras que uno positivo determina un **conexión excitatoria**. Habitualmente, no se suele definir una conexión como de un tipo o de otro, sino que por medio del aprendizaje se obtiene un valor para el peso, que incluye signo y magnitud.

Por otra parte, se puede distinguir entre **conexiones intra-capa** e inter-capa. Las conexiones intra-capa, también denominadas **laterales**, tienen lugar entre las neuronas pertenecientes a una misma capa, mientras que las conexiones inter-capa se producen entre las neuronas de diferentes capas.

Existen además **conexiones realimentadas**, que tienen un sentido contrario al de entrada-salida. En algunos casos puede existir realimentación incluso de una neurona consigo misma.

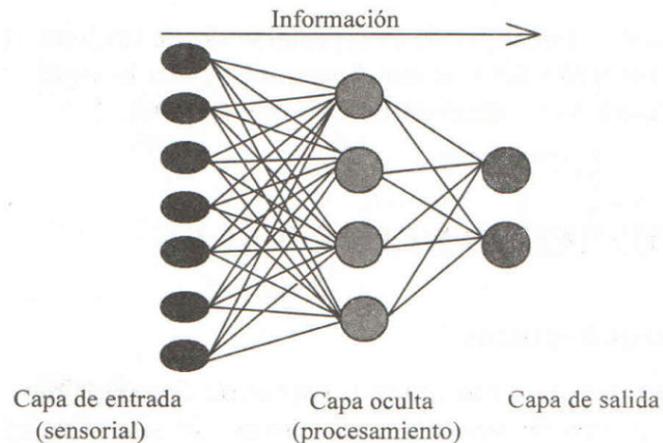


Figura 17. Arquitectura Unidireccional de Tres Capas, de Entrada, Oculta y de salida.

Fuente: Internet

Atendiendo a distintos conceptos, pueden establecerse diferentes tipos de arquitecturas neuronales (Figura 17). Así, en relación a su estructura en capas, podemos hablar de **redes monocapa** y de **redes multicapa**. Las redes monocapa son aquellas compuestas por una única capa de neuronas. Las redes multicapa (layer red networks) son aquellas cuyas neuronas se organizan en varias capas

Asimismo, atendiendo al flujo de datos en la red neuronal, podemos hablar de **redes unidireccionales** (feedforward) y **redes recurrentes** (feedback). En las redes unidireccionales, la información circula en un único sentido, desde las neuronas de entrada hacia las de salida. En las redes recurrentes o realimentadas la información puede circular entre las capas en cualquier sentido, incluido el de salida-entrada.

Por último, también se habla de redes autoasociativas y heteroasociativas. Con frecuencia se interpreta la operación de una red neuronal como la de una **memoria asociativa**, que ante un determinado patrón de entradas responde con un cierto patrón de salida. Si una red se entrena para que ante la presentación de un patrón A responda con otro diferente B, se dice que la red es heteroasociativa.

Si una red es entrenada para que asocie un patrón A consigo mismo, se dice que es autoasociativa (el interés de este tipo de redes, como es el caso de la de Hopfield, reside en que ante la presentación del patrón $A' = A + \text{ruido}$, su respuesta sea el patrón original A, eliminando así el ruido presente en la señal de entrada).

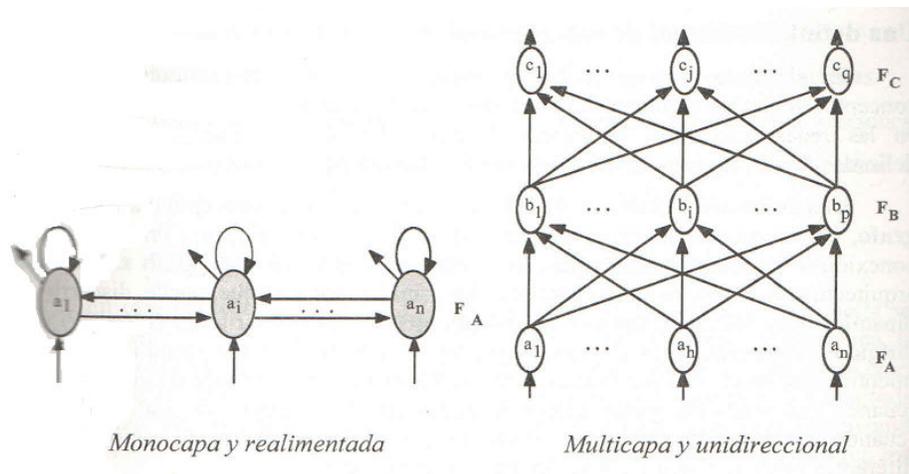


Figura 18. Ejemplos de Arquitecturas Neuronales
Fuente: Internet

3.2. Tipos de Redes Neuronales: Retropropagación y Levenger-Marquardt

Los algoritmos que se utilizarán para la función de entrenamiento serán los de Retropropagación (Backpropagation) y Levenberg-Marquardt.

Algoritmo de Retropropagación

Podemos clasificar las redes neuronales de acuerdo a su arquitectura según dos tipos: redes neuronales con **alimentación directa** y redes neuronales **recurrentes**. En las primeras, la salida de las neuronas no influye en ninguna de sus entradas. En las segundas hay al menos una neurona cuya salida afecta a alguna de sus entradas. La forma habitual de representar la arquitectura de la red es mediante un grafo dirigido donde los vértices representan a las neuronas y un arco (n_i, n_j) indica que la salida de la neurona n_i es una entrada de la neurona n_j . Las redes con alimentación directa son aquellas cuyo grafo es acíclico mientras que en las recurrentes hay al menos un ciclo. Nosotros nos centraremos en el primer tipo de redes, en concreto en el **perceptrón multicapa generalizado**.

En el aprendizaje supervisado tenemos un conjunto de patrones. Cada patrón es un par entrada/salida que la red debe aprender. El objetivo del aprendizaje supervisado es ajustar los pesos sinápticos de la red para que la salida de ésta coincida con la del patrón cuando se le presenta la entrada. Para medir el error que comete la red se usa la suma del error cuadrático que se calcula sumando los cuadrados de las diferencias entre la salida deseada y la obtenida.

El algoritmo de **Retropropagación** (Backpropagation, BP) es un algoritmo de aprendizaje supervisado para redes neuronales basado en el gradiente del error de la red con respecto a los pesos (y umbrales). Para poder escribir las ecuaciones del algoritmo vamos a introducir antes algo de notación.

Un perceptrón multicapa generalizado está formado por un conjunto de neuronas conectadas mediante arcos, formando un grafo que vamos a llamar $R = (N, A)$. El conjunto de neuronas N son los vértices del grafo y el conjunto de arcos A indican las conexiones entre las neuronas. Notaremos la neurona i -ésima mediante n_i . Existe un subconjunto de neuronas en N que son neuronas de entrada y que tienen un comportamiento especial.

Existe también un subconjunto de neuronas que son de salida. Asociado a cada neurona n_i que no sea de entrada existe un valor umbral que denotaremos por θ_i y una función de activación que denotaremos por f_i . Asociado a cada arco de A existe un valor real llamado peso sináptico. Con w_{ij} denotamos el peso sináptico asociado al arco que va de la neurona n_j a la n_i si tal arco existe.

En las redes con alimentación directa (como la que nos ocupa) podemos encontrar una numeración de las neuronas tal que no existan arcos (n_j, n_i) con $j \geq i$. Asumimos que nuestra numeración de las neuronas es de ese tipo.

A las neuronas de entrada les asignaremos el índice más bajo. Así, si decimos que una red tiene dos neuronas de entrada, sabemos que son las neuronas n_1 y n_2 . Entre las neuronas de entrada no puede haber ninguna conexión.

A las neuronas de salida, por el contrario, se les asignará el índice más alto y puede haber conexión entre ellas. La red toma un vector de entrada y realiza cálculos para obtener un vector de salida. La forma en que lo hace la describo a continuación. Cada neurona n_i tiene una salida x_i cuyo valor se calcula de forma distinta si la neurona es de entrada o no. Para la neurona de entrada n_i la salida x_i es la componente i -ésima del vector de entrada que toma la red. Para el resto de las neuronas la salida se calcula mediante la expresión:

$$x_i = f_i(h_i) \quad (\text{Ecuación 3.5})$$

con

$$h(i) = \sum_{j \in \text{Pred}(i)} w_{ij} x_j - \theta_i \quad (\text{Ecuación 3.6})$$

donde $\text{Pred}(i)$ denota al conjunto de los índices de las neuronas predecesoras a n_i en el grafo R . El valor h_i es la suma ponderada de las entradas menos el umbral y recibe el nombre de potencial sináptico de la neurona. Una vez calculadas las x_i de todas las neuronas de la red se forma el vector de salida usando los valores de las neuronas de salida. Llamaremos o al vector de salida de la red y denotaremos sus componentes con subíndices. La expresión del error cuadrático de la red para un solo patrón es:

$$E = \frac{1}{2} \sum_{i=1}^S (t_i - o_i)^2 \quad (\text{Ecuación 3.7})$$

donde el vector t es el vector deseado de salida y S es el número de neuronas de salida.

Normalmente trabajamos con conjuntos de patrones y nos interesa minimizar el error para el conjunto completo de patrones (entrenamiento por lotes). En tal caso el error de la red para el conjunto de patrones se mide mediante la expresión:

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{i=1}^S (t_i^p - o_i^p)^2 \quad (\text{Ecuación 3.8})$$

donde los vectores o^p y t^p denotan la salida de la red y la salida deseada para el patrón p y P es el número de patrones.

Podemos destacar dos modos de funcionamiento del algoritmo: entrenamiento **individualizado** y entrenamiento **por lotes**. En el primero se trabaja patrón a patrón modificando los pesos y umbrales de la red para tratar de reducir su error (Ecuación 3.7). En el segundo se modifican los pesos y umbrales para reducir el error de todos los patrones (Ecuación 3.8). En este último caso los pesos y umbrales se actualizan de acuerdo a las siguientes ecuaciones:

$$w_{ij} \leftarrow w_{ij} + \Delta w_{ij} \quad (\text{Ecuación 3.9})$$

$$\theta_i \leftarrow \theta_i + \Delta\theta_i \quad (\text{Ecuación 3.10})$$

con

$$\Delta w_{ij} = \eta \sum_{p=0}^P \delta_i^p X_j^p \quad (\text{Ecuación 3.11})$$

$$\Delta\theta_i = \eta \sum_{p=0}^P \delta_i^p \quad (\text{Ecuación 3.12})$$

donde para las neuronas de salida

$$\delta_i^p = (t_i^p - o_i^p) f_i'(h_i^p) \quad (\text{Ecuación 3.13})$$

y para el resto de neuronas

$$\delta_i^p = f_i'(h_i^p) \sum_{k \in \text{Suc}(i)} w_{ki} \delta_k^p \quad (\text{Ecuación 3.14})$$

El valor h_i^p es el potencial sináptico de la neurona n_i para el patrón p y $\text{Suc}(i)$ denota al conjunto de los índices de las neuronas sucesoras a n_i en el grafo R . El valor η es la denominada tasa de aprendizaje y regula cuánto avanzamos en el sentido opuesto al gradiente. Un valor alto hace que el aprendizaje sea más rápido: el cambio en los pesos es mayor. Un valor pequeño hace que el aprendizaje sea más lento: el cambio en los pesos es menor. A este algoritmo se le conoce como **regla delta**.

Como puede comprobarse, el cálculo de δ_i^p para neuronas que no son de salida requiere conocer δ_j^p , siendo n_j una neurona sucesora de n_i . Por este motivo, para calcular las δ hay que comenzar por las neuronas de salida y seguir hacia atrás (**de ahí que el algoritmo se llame Retropropagación**). Para las neuronas de entrada no hay que calcular δ .

La regla delta se encuentra con el problema de que a veces un valor de η muy alto puede hacer que la red se vuelva inestable (oscilatoria), mientras que un valor demasiado bajo incrementa en exceso el número de épocas de entrenamiento. Para aliviar este problema surgió el **aprendizaje con momentos o regla delta generalizada** que consiste en añadir un término con efecto estabilizador en las Ecuaciones 3.24 y 3.25. Las nuevas Ecuaciones son:

$$\Delta w_{ij}(t+1) = \alpha \Delta w_{ij}(t) + \eta \sum_{p=0}^P \delta_i^p X_j^p \quad (\text{Ecuación 3.15})$$

$$\Delta\theta_i(t+1) = \alpha \Delta\theta_i(t) + \eta \sum_{p=0}^P \delta_i^p \quad (\text{Ecuación 3.16})$$

donde α es la constante de momentos. Debe cumplirse $0 \leq |\alpha| < 1$. Puede verse que ahora el cambio en los pesos (y los umbrales) no solo depende del gradiente de la función de error, sino que también depende del cambio que se produjo en la época anterior. Con la inclusión del término momento el algoritmo de Retropropagación tiende a acelerar la bajada en las direcciones de descenso constante (cuando la función de error no cambia mucho), mientras que si el gradiente cambia en iteraciones sucesivas, las modificaciones en los pesos se hacen pequeñas.

Hemos llamado δ_i^p al elemento i -ésimo del vector de entrada del patrón p -ésimo. Debemos tener en cuenta que o_i es la salida de la i -ésima neurona de salida, que también puede denotarse con $x_{\text{neurons}}-S^+_i$.

Lo primero que hace el algoritmo es inicializar los pesos de la red y poner a cero los incrementos de los pesos y los umbrales. Dentro del bucle, lo primero que hace es inicializar con cero los elementos de los arrays donde almacenará el gradiente del error. Luego entra en un bucle cuyo cuerpo se ejecuta para cada patrón. Calcula la salida de la red y los valores de delta, para después actualizar el array del gradiente sumándole el

gradiente del error para el patrón en consideración. Tras salir del bucle actualiza los incrementos de los pesos y umbrales para después hacer lo mismo con los propios pesos y umbrales.

Esto se repite hasta que se da cierta condición de parada. Las condiciones de parada más habituales son: alcanzar un número de épocas, reducir el error en el conjunto de patrones de entrenamiento hasta un cierto valor o reducir dicho error para un conjunto distinto de patrones llamado conjunto de validación⁸.

El pseudocódigo del algoritmo de Retropropagación se puede ver en la Figura 19.

```

inicializa_pesos;
 $\Delta w_{ij} := 0$  // Se inicializan los incrementos
 $\Delta \theta_i := 0$ 
MIENTRAS NO condición_parada HACER
  PARA i := 1..neurons HACER
    PARA j := 1..i HACER
      wght[i][j] := 0;
    FINPARA;
    thr[i] := 0;
  FINPARA;

  PARA p := 1..P HACER
    PARA i := 1..neurons HACER // Se aplica el patrón p a la entrada
      SI  $n_i$  es de entrada ENTONCES
         $x_i := s_i^p$ ;
      SINO
         $h_i := \sum_{j \in Pred(i)} w_{ij} x_j - \theta_i$ ;
         $x_i := f_i(h_i)$ ;
      FINSI;
    FINPARA;

    PARA i := neurons..1 HACER // Se calculan los  $\delta$ 
      SI  $n_i$  es de salida ENTONCES
         $\delta_i := (t_i^p - o_i) f'_i(h_i)$ ;
      SINO SI  $n_i$  no es de entrada ENTONCES
         $\delta_i := f'_i(h_i) \sum_{k \in Suc(i)} w_{ki} \delta_k$ ;
      FINSI;
    FINPARA;

    PARA i := 1.. neurons HACER // Se calcula actualiza gradiente
      PARA j := 1..i HACER
        wght[i][j] := wght[i][j] +  $\delta_i x_j$ ;
      FINPARA;
      thr[i] := thr[i] +  $\delta_i$ ;
    FINPARA;

  FINPARA;

  PARA i := 1..neurons HACER // Actualiza los pesos e incrementos
    PARA j := 1..i HACER
       $\Delta w_{ij} := \alpha \cdot \Delta w_{ij} + \eta \cdot wght[i][j]$ ;
       $w_{ij} := w_{ij} + \Delta w_{ij}$ ;
    FINPARA;
     $\Delta \theta_i := \alpha \cdot \Delta \theta_i + \eta \cdot thr[i]$ 
     $\theta_i := \theta_i + \Delta \theta_i$ ;
  FINPARA;
FINMIENTRAS;

```

Figura 19: Algoritmo de Retropropagación (BP)

Fuente: Internet

⁸ <http://neo.lcc.uma.es/staff/francis/pdf/PFC-Chicano03.pdf>. pp 31-36

Algoritmo Levenberg–Marquardt

Una vez fijo el conjunto de patrones con el que vamos a entrenar la red la fórmula del error de la red E (Ecuación 3.8) tan sólo depende de los pesos y los umbrales. A partir de ahora llamaremos w al vector que contiene a los pesos y umbrales de la red.

El algoritmo de Retropropagación calcula el gradiente del error con respecto a los pesos y umbrales, es decir, $\nabla E(w)$ y actualiza los pesos e incrementos en función de ese vector.

Con la nueva notación las Ecuaciones 3.9, 3.10, 3.15 y 3.16, pueden resumirse en las dos siguientes:

$$\Delta w(t+1) = \alpha \Delta w(t) - \eta \nabla E(w(t)) \quad (\text{Ecuación 3.17})$$

$$w(t+1) \leftarrow w(t) + \Delta w(t+1) \quad (\text{Ecuación 3.18})$$

Hagamos por un momento $\alpha = 0$ en la Ecuación 3.17. Entonces tenemos la regla delta y el incremento en el vector de pesos se calcula mediante la expresión $\Delta w = -\eta \nabla E(w)$.

Esta expresión procede de una aproximación de la función de error mediante el primer término del desarrollo en series de Taylor esto es:

$$E(w + \Delta w) \approx E(w) + \nabla E(w)^T \Delta w \quad (\text{Ecuación 3.19})$$

A partir de esa ecuación se elige un valor para Δw que tenga la misma dirección y sentido opuesto a $\nabla E(w)$ para que el error disminuya.

Si en lugar de realizar una aproximación lineal de la función de error realizamos una cuadrática usando los dos primeros términos del desarrollo en series de Taylor obtenemos la expresión:

$$\Delta E(w) \approx \nabla E(w)^T \Delta w + 1/2 \Delta w^T H(w) \Delta w \quad (\text{Ecuación 3.20})$$

donde $H(w)$ es la matriz Hessiana de E con respecto a w y $\Delta E(w) = E(w+\Delta w) - E(w)$.

Diferenciando con respecto a Δw , igualando a cero y despejando tenemos:

$$\Delta w = -H^{-1} \nabla E(w) \quad (\text{Ecuación 3.21})$$

La Ecuación anterior nos permite calcular el valor de Δw que minimiza el cambio $\Delta E(w)$. Este es el método de Newton, que consigue en muchos casos mejores resultados que la Retropropagación pero requiere calcular derivadas de segundo orden.

Existe una aproximación al método de Newton que no requiere dicho cálculo y que es conocido como **Levenberg–Marquardt**. Es más potente que el método del gradiente descendiente pero requiere más memoria. Llamaremos $e^p(w)$ al vector de error de la red para el patrón p cuando los pesos tienen valor w , esto es:

$$e_i^p(w) = t_i^p - o_i^p(w) \quad (\text{Ecuación 3.22})$$

Nótese que ahora indicamos explícitamente que el valor de la salida de la red depende del valor de los pesos sinápticos (el hecho de que antes no se indicara esta dependencia no significa que no existiera). Podemos escribir lo siguiente:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{p=1}^P \mathbf{e}^p(\mathbf{w})^T \mathbf{e}^p(\mathbf{w}) \quad (\text{Ecuación 3.23})$$

$$\nabla E(\mathbf{w}) = \sum_{p=1}^P J^p(\mathbf{w})^T \mathbf{e}^p(\mathbf{w}) \quad (\text{Ecuación 3.24})$$

$$H(\mathbf{w}) = \sum_{p=1}^P \left(J^p(\mathbf{w})^T J^p(\mathbf{w}) + S^p(\mathbf{w}) \right) \quad (\text{Ecuación 3.25})$$

donde $H(\mathbf{w})$ es la matriz Hessiana de E evaluada en \mathbf{w} , $S^p(\mathbf{w})$ es una matriz dependiente de las segundas derivadas de $e(\mathbf{w})$ y $J^p(\mathbf{w})$ es la matriz Jacobiana de e^p evaluada en \mathbf{w} , la cual puede expresarse como:

$$J^p(\mathbf{w}) = \begin{bmatrix} \nabla e_1^p(\mathbf{w}) \\ \vdots \\ \nabla e_S^p(\mathbf{w}) \end{bmatrix} = \begin{bmatrix} \frac{\partial e_1^p}{\partial w_1}(\mathbf{w}) & \cdots & \frac{\partial e_1^p}{\partial w_Q}(\mathbf{w}) \\ \vdots & \ddots & \vdots \\ \frac{\partial e_S^p}{\partial w_1}(\mathbf{w}) & \cdots & \frac{\partial e_S^p}{\partial w_Q}(\mathbf{w}) \end{bmatrix} \quad (\text{Ecuación 3.26})$$

donde Q es el número de pesos más el de umbrales. Ahora tomamos

$$\Delta \mathbf{w} = -\alpha M(\mathbf{w}) \nabla E(\mathbf{w}) \quad (\text{Ecuación 3.27})$$

para modificar los pesos. El valor de la matriz M usado por el método es $M(\mathbf{w}) = [\mu I + H(\mathbf{w})]^{-1}$ donde μ es algún valor no negativo. Además el valor de la Hessiana es sustituido por $\sum_{p=1}^P J^p(\mathbf{w})^T J^p(\mathbf{w})$, asumiendo que $S^p(\mathbf{w}) \cong 0$. Con todo esto llegamos al método de Levenberg–Marquardt (LM) que queda resumido en la siguiente expresión:

$$\Delta \mathbf{w} = -\alpha \left[\mu I + \sum_{p=1}^P J^p(\mathbf{w})^T J^p(\mathbf{w}) \right]^{-1} \nabla E(\mathbf{w}) \quad (\text{Ecuación 3.28})$$

El parámetro μ se incrementa o disminuye en cada paso. Si $E(\mathbf{w}(t+1)) \leq E(\mathbf{w}(t))$ entonces en la siguiente iteración μ se divide por un factor β . En caso contrario en la siguiente iteración el parámetro μ se multiplica por β . En se sugiere tomar $\beta = 10$ y $\mu = 0.01$ al comienzo, sin embargo, nosotros hemos usado $\mu = 0.001$ tal y como hace MATLAB.

El algoritmo Levenberg–Marquardt actúa sobre los P patrones a la vez como sigue:

1. Calcula la salida de la red y los vectores de error $\mathbf{e}^p(\mathbf{w})$ para cada uno de los patrones.
2. Calcula la matriz Jacobiana $J^p(\mathbf{w})$ para cada patrón usando entre otras cosas el vector de error $\mathbf{e}^p(\mathbf{w})$.
3. Calcula $\Delta \mathbf{w}$ usando la Ecuación 3.28 y los resultados anteriores.
4. Vuelve a calcular el error usando $\mathbf{w} + \Delta \mathbf{w}$ como pesos de la red. Si el error ha disminuido divide μ por β , hace la asignación $\mathbf{w} \leftarrow \mathbf{w} + \Delta \mathbf{w}$ y vuelve al paso 1. Si el error no disminuye multiplica μ por β y vuelve al paso 3.
5. $[\mu I + \sum_{p=1}^P J^p(\mathbf{w})^T J^p(\mathbf{w})]$. El algoritmo acaba cuando la norma del gradiente es menor que un valor predeterminado o el error se ha reducido por debajo de un objetivo.

El pseudocódigo podemos verlo en la Figura 20.

Cuando se pasa el algoritmo LM de la teoría a la práctica hay que tratar con ciertos problemas como puede ser la singularidad de la matriz⁹

```

inicializa_pesos;
MIENTRAS NO condición_parada HACER
  calcula  $e^p(\mathbf{w})$  para cada patrón;
   $e1 := \frac{1}{2} \sum_{p=1}^P e^p(\mathbf{w})^T e^p(\mathbf{w})$ ;
  calcula el Jacobiano para cada patrón;
  REPITE
    calcula  $\Delta \mathbf{w}$ ;
     $e2 := \frac{1}{2} \sum_{p=1}^P e^p(\mathbf{w} + \Delta \mathbf{w})^T e^p(\mathbf{w} + \Delta \mathbf{w})$ ;
    SI ( $e1 \leq e2$ ) ENTONCES
       $\mu := \mu * \beta$ ;
    FINSI;
  HASTA ( $e2 < e1$ );
   $\mu := \mu / \beta$ ;
   $\mathbf{w} := \mathbf{w} + \Delta \mathbf{w}$ ;
FINMIENTRAS;

```

Figura 20: Algoritmo Levenberg–Marquardt (LM).
Fuente: Internet

3.3. Porcentaje de Erro Absoluto MAPE:

Error Porcentual Absoluto Medio (MAPE): Mide el tamaño del error en términos porcentuales. Se calcula como el promedio de las diferencias absolutas entre los valores pronosticados y los reales y se expresa como porcentaje de los valores reales.

Muchas empresas se centran principalmente en el MAPE para evaluar la **exactitud del pronóstico**. La mayoría de las personas se siente más cómoda pensando en términos porcentuales, por lo que esta medida del error es muy fácil de interpretar. También se puede transmitir cuando no se sabe la información sobre el volumen de la demanda de un determinado ítem. Por ejemplo, decirle al gerente “Nos quedamos por debajo del 4% del artículo x” es más significativo que decirle “nos quedamos por debajo de 3.000 unidades del artículo x”, dado que el gerente no siempre sabe la demanda del artículo x.

El MAPE es una escala sensible y no se debe utilizar cuando se trabaja con un volumen de datos bajo. Lo anterior se debe a que el denominador de la ecuación del MAPE (REAL) es indefinido si la demanda REAL es cero, por otra parte, cuando REAL no es cero, pero es un valor pequeño, el MAPE toma frecuentemente valores extremos. Esta sensibilidad de la escala hace que el MAPE se acerque sin valor como una medida de error para los datos de bajo volumen.

Este criterio se utiliza para examinar cual de los modelos examinados mse ajusta mejor a la serie objeto de estudio, en este caso el consumo de ancho de banda para internet de la universidad nacional de la amazonia peruana UNAP.

⁹ <http://neo.lcc.uma.es/staff/francis/pdf/PFC-Chicano03.pdf> . pp 35-39

El MAPE es un número positivo, el que para efectos de decidir cuál de los modelos se ajusta mejor a los datos, se deben comparar sus MAPE's y seleccionar aquel que muestre el MAPE más bajo, generalmente igual o por debajo del nivel 0.05.¹⁰

La fórmula utilizada para el cálculo del MAPE es¹¹:

$$\left(\frac{1}{n} \sum \frac{|Actual - Forecast|}{|Actual|} \right) * 100$$

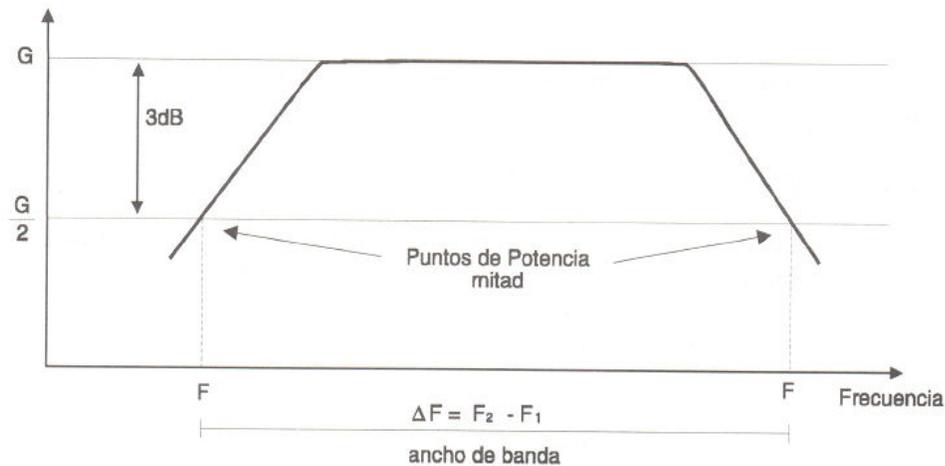
Month	Actual	Forecast	Absolute Percent Error
1	112.3	124.7	11.0%
2	108.4	103.7	4.3%
3	148.9	116.6	21.7%
4	117.4	78.5	33.1%
MAPE			17.6%

ITEM	VENTA REAL (VR)	ESTIMACIÓN VENTA (EV)	ERROR UNIDADES EU = VR - EV	ERROR PORCENTUAL ABSOLUTO (EPA) EPA = (EU/VR)*100%
1129	4.463	3.833	630	14,1%
1130	4.683	4.354	329	7%
1131	4.376	4.280	96	2,2%
1132	4.776	4.860	84	1,8%
1133	3.908	3.500	408	10,4%
1134	4.816	4.800	16	0,3%
1135	3.862	3.900	38	1%
1136	4.594	4.200	394	8,6%
1137	4.075	4.350	275	6,7%
1138	3.953	4.000	47	1,2%
1139	3.724	3.890	166	4,5%
1140	4.905	5.604	699	14,3%
1141	3.908	4.350	442	11,3%
1142	3.803	4.000	197	5,2%
SUMA DE ERRORES PORCENTUALES				88,6%

¹⁰ <http://www.assis.com.co/blog-2/error-porcentual-absoluto-medio-mape/>

¹¹ <http://www.pronosticoexperto.com/la-anatomia-de-un-pronostico.html>

La figura 22, muestra la curva típica de ganancia de un amplificador en función de la frecuencia, que recibe el nombre particular de “respuesta en frecuencia”.



*Figura 22. Ganancia de un amplificador
Fuente: Internet*

Por lo tanto, carece de sentido en un amplificador indicar la magnitud de la ganancia a menos que se señale simultáneamente la frecuencia a la que ha sido medida. Precisamente las frecuencias a las cuales la ganancia de potencia de un amplificador cae al 50% del valor correspondiente de las frecuencias medias, se conoce con el nombre de “frecuencias de corte”. Estas constituyen precisamente el límite inferior y superior del ancho de banda.

Efecto del Ancho de Banda, cuando una Señal pasa a través de un Medio Físico de Transmisión.

Cuando una señal cuadrada, rectangular o en general cualquier señal digital pasa a través de un soporte físico, siempre sufre una deformación, producida por lo que se denomina el “ancho de banda pasante” del medio.

El ancho de banda pasante es el intervalo de frecuencias:

$$\Delta f = f_2 - f_1 \quad (\text{Ecuación 3.30})$$

Tal que: Las componentes de la serie de Fourier, cuyas frecuencias están comprendidas entre esos límites, sufren atenuaciones de hasta 3 dB.

Las que se encuentran por arriba y por debajo de esos límites son atenuadas más fuertemente y el medio actúa como un filtro que solo deja pasar, a los efectos prácticos, las del ancho de banda señalado.

Se dice entonces que el medio de comunicaciones se comporta como un “filtro pasa banda”. Estos filtros tienen la característica de dejar pasar las frecuencias comprendidas dentro de una banda, cuyos límites están dados precisamente por el valor más alto y el más bajo de los arriba indicados.

Si el ancho de banda fuese teóricamente infinito, es decir que $f_1 = 0$ y $f_2 = \infty$, entonces todas las armónicas de la señal pasarían sin atenuación y, por lo tanto, la señal no sufriría deformación alguna.

Sin embargo, en la práctica esto no sucede y a medida que el ancho de banda es menor, mayor es la deformación de la señal.

En el ejemplo de la figura 23, se puede ver como la señal se deforma a medida que el ancho de banda disminuye.

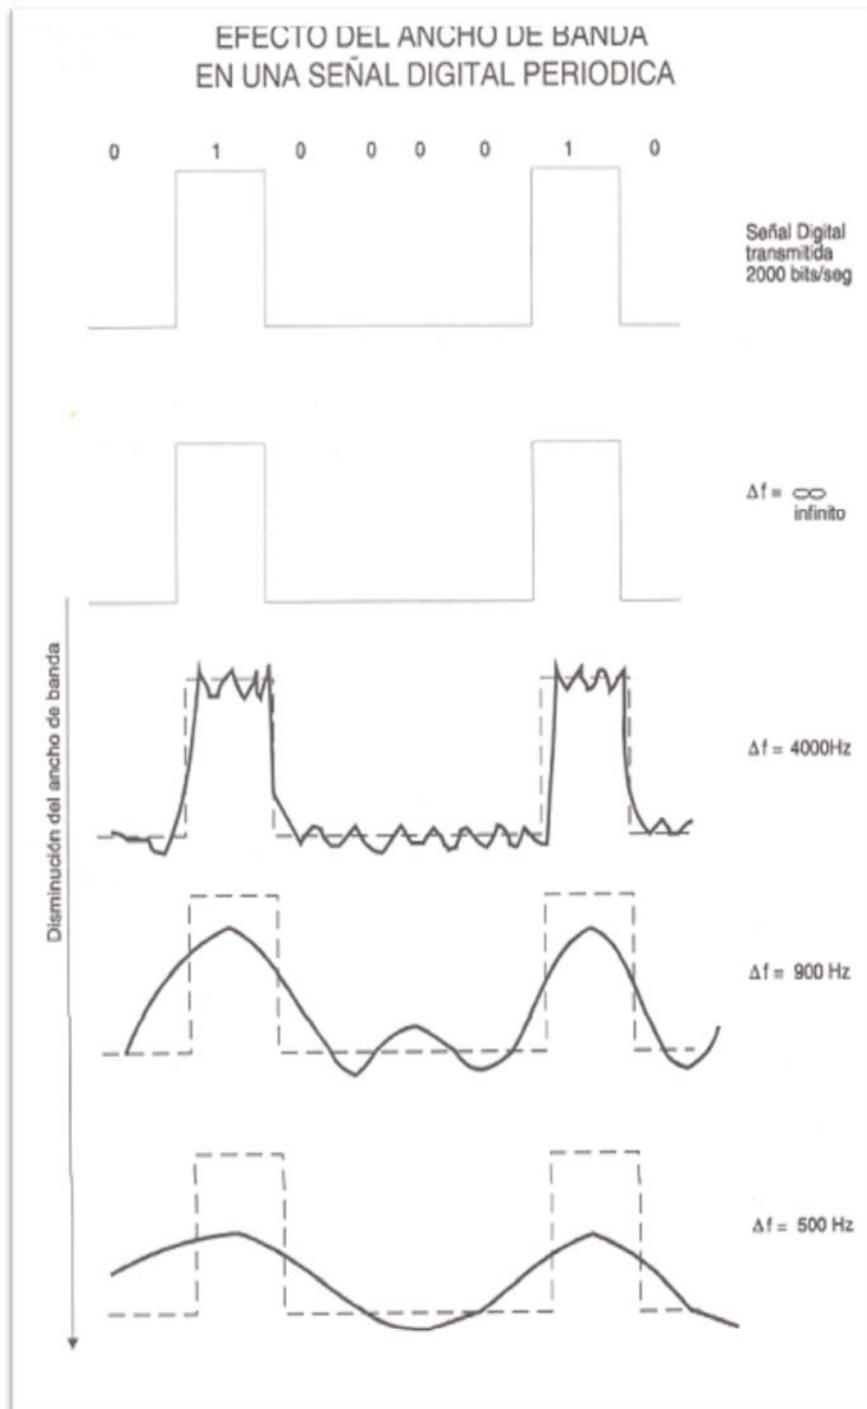


Figura 23. Espectro del Ancho de Banda en una Señal Digital Periódica
Fuente: Internet

El Análisis de Fourier

A principio del siglo XIX, el matemático francés Jean-Baptiste Fourier probó que cualquier función periódica de comportamiento razonable, $g(t)$ con un periodo T , se puede construir sumando una cantidad (posiblemente infinita) de senos y cosenos:

$$g(t) = \frac{1}{2} c + \sum_{n=1}^{\infty} a_n \text{sen}(2\pi nft) + \sum_{n=1}^{\infty} b_n \text{cos}(2\pi nft) \quad (\text{Ecuación 3.31})$$

Donde $f = 1/T$ es la frecuencia fundamental, a_n y b_n son las amplitudes de seno y coseno de los n -ésimos (términos) **armónicos** y c es una constante. Tal descomposición se conoce como **serie de Fourier**. A partir de ella, es posible reconstruir la función, es decir, si se conoce el periodo T y se dan las amplitudes, la función original del tiempo puede encontrarse realizando las sumas que se muestran en la Ecuación

Una señal de datos que tenga una duración finita (la cual todas poseen) se puede manejar con solo imaginar que el patrón se repite una y otra vez por siempre (es decir el intervalo de T a $2T$ es el mismo que de 0 a T , etc.).

Las amplitudes a_n se pueden calcular para cualquier $g(t)$ dada multiplicando ambos lados de la ecuación 3.31 por $\text{sen}(2\pi kft)$ y después integrando de 0 a T . Puesto que

$$\int_0^T \text{sen}(2\pi kft) \text{sen}(2\pi nft) dt = \begin{cases} 0 & \text{para } k \neq n \\ \frac{T}{2} & \text{para } k = n \end{cases} \quad (\text{Ecuación 3.32})$$

Sólo un término de la sumatoria perdura: a_n . La sumatoria de b_n desaparece por completo. De manera similar, al multiplicar la ecuación 3.31 por $\text{cos}(2\pi kf)$ e integrando entre 0 y T , podemos derivar b_n . Con solo integrar ambos lados de la ecuación como está, podemos encontrar c . Los resultados de realizar estas operaciones son los siguientes:

$$a_n = \frac{2}{T} \int_0^T g(t) \text{sen} [(2\pi nft)] dt \quad b_n = \frac{2}{T} \int_0^T g(t) \text{cos} [(2\pi nft)] dt$$

$$c = \frac{2}{T} \int_0^T g(t) dt \quad (\text{Ecuación 3.33})$$

Señales de Ancho de Banda Limitado

Para ver cómo se relaciona todo esto con la comunicación de datos, consideremos un ejemplo específico: la transmisión del carácter "b" ASCII codificado en un byte de 8 bits. El patrón de bits que se va a transmitir es 01100010. La parte izquierda de la Figura 24(a) muestra la salida de voltaje que produce la computadora trasmisora. El análisis de Fourier de la señal produce los coeficientes:

$$a_n = \frac{1}{\pi n} \left[\cos\left(\frac{\pi n}{4}\right) - \cos\left(\frac{3\pi n}{4}\right) + \cos\left(\frac{6\pi n}{4}\right) - \cos\left(\frac{7\pi n}{4}\right) \right]$$

$$b_n = \frac{1}{\pi n} \left[\sin\left(\frac{3\pi n}{4}\right) - \sin\left(\frac{\pi n}{4}\right) + \sin\left(\frac{7\pi n}{4}\right) - \sin\left(\frac{6\pi n}{4}\right) \right]$$

$$c = \frac{3}{4} \quad \text{(Ecuación 3.34)}$$

En el lado derecho de la figura 3.18(a) se muestran las amplitudes de raíz cuadrada media, $\sqrt{a_n^2 + b_n^2}$, para los primeros términos. Estos valores son importantes porque sus cuadrados son proporcionales a la energía transmitida en la frecuencia correspondiente.

Ninguna instalación transmisora puede transmitir señales sin perder cierta potencia en el proceso. Si todos los componentes de Fourier disminuyeran en la misma proporción, la señal resultante se reduciría en amplitud, pero no se distorsionaría (es decir, tendría la misma forma de onda cuadrada que tiene en la figura 24(a).

Desgraciadamente, todas las instalaciones de transmisión disminuyen los distintos componentes de Fourier en diferente grado, lo que provoca distorsión.

Por lo general, las amplitudes se transmiten sin ninguna disminución desde 0 hasta cierta frecuencia f_c [medida en ciclos/seg o Hertz (Hz)] y todas las frecuencias que se encuentren por arriba de esta frecuencia de corte serán atenuadas.

El rango de frecuencias que se transmiten sin atenuarse con fuerza se conoce como **ancho de banda**.

En la práctica, el corte en realidad no es abrupto, por lo que con frecuencia el ancho de banda ofrecido va desde 0 hasta la frecuencia en la que el valor de la amplitud es atenuado a la mitad de su valor original.

El ancho de banda es una propiedad física del medio de transmisión y por lo general depende de la construcción, grosor y longitud de dicho medio.

En algunos casos, se introduce un filtro en el circuito para limitar la cantidad de ancho de banda disponible para cada cliente.

Por ejemplo, un cable de teléfono podría tener un ancho de banda de 1 MHz para distancias cortas, pero las compañías telefónicas agregan un filtro que restringe a cada cliente a aproximadamente 3,100 Hz.

Este ancho de banda es adecuado para el lenguaje inteligible y mejora la eficiencia del sistema al limitar a los usuarios en el uso de los recursos.

Ahora consideremos como luciría la señal de la figura 24(a) si el ancho de banda fuera tan lento que sólo las frecuencias más bajas se transmitieran, es decir, si la función fuera aproximada por los primeros términos de la ecuación.

La figura 24(b) muestra la señal que resulta de un canal que permite que sólo pase la primera armónica (la fundamental, f). De manera similar, la figura 24(c) – (e) muestra el espectro y las funciones reconstruidas de canales de ancho de banda más grande.

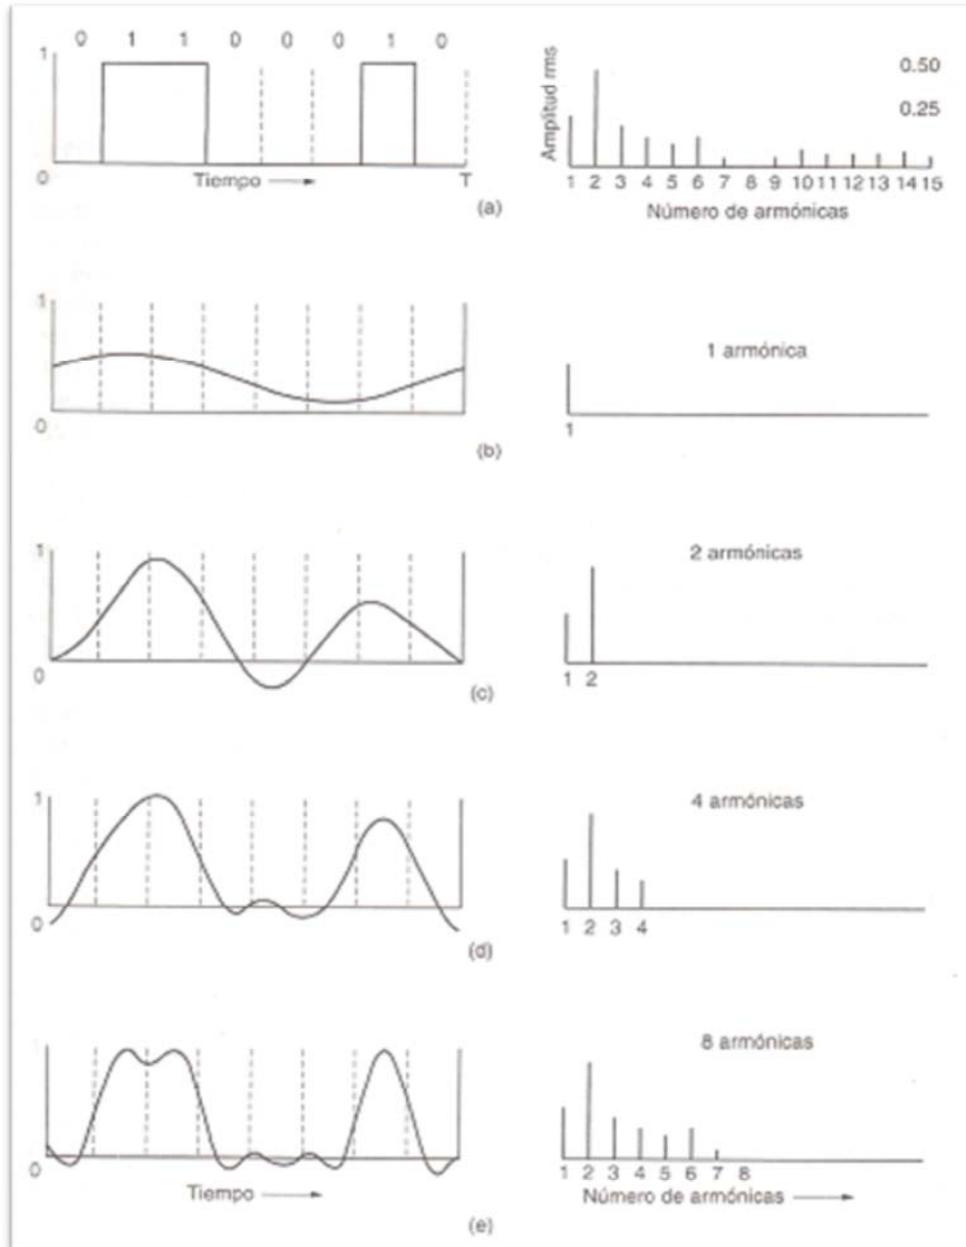


Figura 24. (a) Una señal binaria y sus amplitudes de raíz cuadrada media de Fourier. (b) – (e) Aproximaciones sucesivas a la señal original.

Fuente: Internet

Dada una tasa de bits de b bits/seg, el tiempo requerido para enviar 8 bits (por ejemplo) 1 bit a la vez es $8/b$ seg, por lo que la frecuencia de la primera armónica es $b/8$ Hz.

Una línea telefónica normal, llamada con frecuencia **línea con calidad de voz**, tiene una frecuencia de corte introducida de manera artificial arriba de 3000 Hz. Esta restricción significa que el número de armónicas más altas que pasan es de aproximadamente $2000/(b/8)$ o $24,000/b$ (el corte no es abrupto).

Para algunas tasas de datos, los números resultan como se muestra en la Tabla 7.

Tabla 7. Relación entre tasa de datos y armónicas

Bps	T(mseg)	Primera armónica (Hz)	# de armónicas enviadas
300	26.67	37.5	80
600	13.33	75	40
1200	6.67	150	20
2400	3.33	300	10
4800	1.67	600	5
9600	0.83	1200	2
19200	0.42	2400	1
38400	0.21	4800	0

Fuente: Elaboración propia

A partir de estos números, queda claro que tratar de transmitir a 9600 bps por una línea telefónica transformará la figura 24(a) en algo similar a lo que se muestra en la figura 24(c), lo que dificulta la recepción precisa del flujo de bits binarios original.

Debería ser obvio que a tasas de datos mucho mayores que 38.4 Kbps, no hay la menor esperanza para las señales binarias, aun si la transmisión se encuentra completamente libre de ruidos.

En otras palabras, limitar el ancho de banda limita la tasa de datos, incluso en canales perfectos. Sin embargo, existen esquemas de codificación refinados que utilizan diferentes niveles de voltaje y pueden alcanzar tasas de datos mayores.

La Tasa de Datos Máxima de un canal

En 1924, un ingeniero de AT&T, Henry Nyquist, se dio cuenta de que incluso un canal perfecto tiene una capacidad de transmisión finita.

Derivó una ecuación que expresa la tasa de datos máxima para un canal sin ruido de ancho de banda finito. En 1948, Claude Shannon continuó el trabajo de Nyquist y lo extendió al caso de un canal sujeto a ruido aleatorio (es decir, termodinámico)(Shannon, 1948). Sólo resumiremos brevemente sus ahora clásicos resultados.

Nyquist probó que si se pasa una señal cualquiera a través de un filtro pasa-bajas de ancho de banda H , la señal filtrada se puede reconstruir por completo tomando solo $2H$ muestras (exactas) por segundo. No tiene sentido muestrear la línea a una rapidez mayor que $2H$

veces por segundo porque los componentes de mayor frecuencia que tal muestreo puede recuperar ya se han filtrado. Si la señal consiste en V niveles discretos, el teorema de Nyquist establece:

$$\text{tasa de datos máxima} = 2H \log_2 V \text{ bits/seg} \quad (\text{Ecuación 3.35})$$

Por ejemplo, un canal sin ruido de 3 KHz no puede transmitir señales binarias (es decir, de dos niveles) a una tasa mayor que 6000 bps.

Hasta aquí solo hemos considerado canales sin ruido. Si el ruido aleatorio está presente, la situación se deteriora rápidamente. Y el ruido aleatorio (térmico) siempre está presente debido al movimiento de las moléculas del sistema. La cantidad de ruido térmico presente se mide por la relación entre la potencia de la señal y la potencia de ruido, llamada relación señal a ruido. Si indicamos la potencia de la señal con una S y la potencia del ruido con N , la relación señal a ruido es S/N . Por lo general, la relación misma no se expresa; en su lugar, se da la cantidad $10 \log_{10} S/N$. Estas unidades se conocen como **decibeles (dB)**. Una relación S/N de 10 es 10 dB, una relación de 100 es 20 dB, una de 1000 es 30 dB, y así sucesivamente. Los fabricantes de amplificadores estereofónicos a menudo caracterizan el ancho de banda (rango de frecuencias) en el cual su producto es lineal dando la frecuencia de 3 dB en cada extremo.

Estos son los puntos a los que el factor de amplificación ha sido dividido (puesto que $\log_{10} 3 \approx 0.5$).

El resultado principal de Shannon es que la tasa de datos máxima de un canal ruidoso cuyo ancho de banda es H Hz y cuya relación señal a ruido es S/N , está dado por:

$$\text{Número máximo de bits/seg} = H \log_2 (1 + S/N) \quad (\text{Ecuación 3.36})$$

Por ejemplo, un canal con un ancho de banda de 3000Hz y con una relación señal a ruido térmico de 30 dB (los parámetros típicos de la parte analógica del sistema telefónico) no puede transmitir más allá de 30,000 bps, sin importar cuántos niveles de señal se utilicen, ni con qué frecuencia se tomen los muestreos. El resultado de Shannon se dedujo aplicando argumentos de la teoría de la información y es válido para cualquier canal sujeto a ruido térmico.

Los ejemplos contrarios se deben clasificar en la misma categoría de las máquinas de movimiento perpetuo. Sin embargo, cabe señalar que éste solamente es un límite superior y que los sistemas reales rara vez lo alcanzan.

Ancho de Banda Analógico

El **ancho de banda analógico** se refiere normalmente al rango de frecuencia de un sistema electrónico analógico. Por ejemplo, el ancho de banda analógico podría utilizarse para describir el rango de frecuencias radiadas por una estación de radio FM. El ancho de banda analógico también podría referirse al rango de frecuencias que pueden propagarse por un cable de cobre (Hz). Existe una correlación directa entre el ancho de banda de cualquier medio y la velocidad en bits por segundo que el medio puede soportar.

Ancho de Banda Digital

El **ancho de banda digital** es una medida de cómo la información puede fluir de un lugar a otro en un periodo de tiempo dado. Este ancho se mide en bits por segundo. En las comunicaciones de datos, el término ancho de banda significa a menudo ancho de banda digital.

El rendimiento se refiere al **ancho de banda real**, medido. En algunos casos, se restringe más aun para incluir únicamente datos reales, descartando de los totales computados la sobrecarga de cualquier protocolo, como las cabeceras, las informaciones finales y los mensajes de protocolo. Independientemente del método de computación exacto, el rendimiento real queda lejos del máximo ancho de banda digital posible del medio que se está utilizando. Muchos factores afectan al rendimiento, incluyendo el medio, la distancia, el ruido y los protocolos utilizados.

Al diseñar una red, es importante tener en cuenta el ancho de banda teórico. La red nunca será más rápida de lo que el medio permita. Una consideración relacionada con esto es la cantidad de ancho de banda que las aplicaciones de usuarios necesitan. La figura 25 ilustra los diferentes métodos de conexión a Internet y sus anchos de banda correspondientes en Kbps. En la figura también se muestran algunas aplicaciones de Internet típicas y sus correspondientes necesidades de ancho de banda.

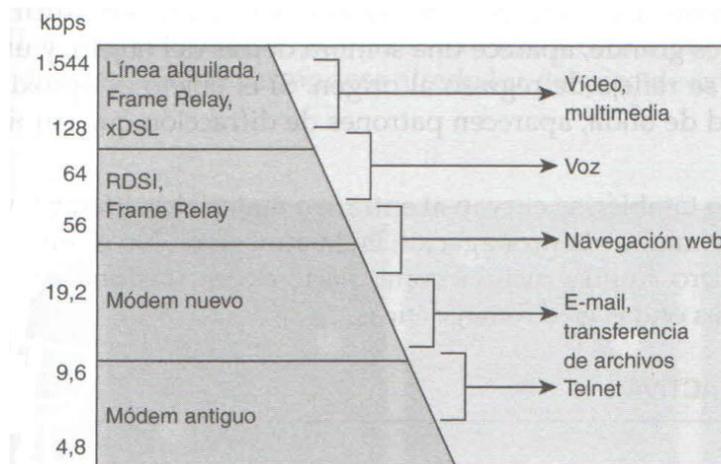


Figura 25. Necesidades de Ancho de Banda de las aplicaciones.

Fuente: Internet

Tasa de Bits

En informática y telecomunicación, el **termino tasa de bits** (en inglés: **bitrate**) define el número de bits que se transmiten por unidad de tiempo a través de un sistema de transmisión digital o entre dos dispositivos digitales. Así pues, es la velocidad de transferencia de datos.

La tasa de transferencia se refiere al ancho de banda real medido en un momento concreto del día empleando rutas concretas de internet mientras se transmite un conjunto específico de datos, desafortunadamente, por muchas razones la tasa es con frecuencia menor al ancho de banda máximo del medio que se está empleando.

Los siguientes son algunos de los factores que determinan la tasa de transferencia:

- Dispositivos de Internet-Working
- Tipos de datos que se van a transferir
- Topología de la red

- Número de usuarios en la red
- La computadora del usuario
- El servidor
- Condiciones de la energía
- Congestión

El ancho de banda teórico de la red es una consideración importante en el diseño de la red, porque la tasa de transferencia de la red nunca es mayor que dicho ancho de banda, debido a las limitaciones puestas por el medio y a las tecnologías de red elegidas.

La unidad con que el Sistema Internacional de Unidades expresa el bitrate es el **bit por segundo** (bits/s, b/s, bps). La b debe escribirse siempre en minúscula, para impedir la confusión con **byte por segundo** (B/s). Para convertir de bytes/s a bits/s, basta simplemente multiplicar por “8” y viceversa. “Incorrecto no olvidemos que el protocolo IP usa datagramas 1500 bytes para el tráfico de datos y no olvidemos que cada paquete se envía con cabeceras, así que dependiendo de las tecnologías de acceso y las tecnologías WAN usan estas cabeceras se van acrecentando, lo que hace complicado hacer una conversión tan sencilla”.

Velocidades típicas de los accesos de conexión a Internet:

- Modem RTB: 56 Kbps = 7kB/s (7Kilobytes por segundo)
- ADSL: 1024 Kbps (nominal 1 Mbps) = 128 KBps (128 Kilobytes por segundo)
- Cable: 2400 Kbps = 300 KBps (300 Kilobytes por segundo)
- VSAT: 600 Kbps = 75 KBps (75 Kilobytes por segundo)
- Telefonía móvil 3G: 384 Kbps = 48 KBps (48 Kilobytes por segundo)

Las velocidades de conexión a Internet son brutas. En la práctica, la velocidad neta disponible para el usuario, suele ser entre un 10-15% menor, debido al ancho de banda consumido por las cabeceras y las colas de los protocolos.

Otro error frecuente es utilizar el baudio como sinónimo de bit por segundo. **La velocidad en baudios o baudrate** no debe confundirse con la **tasa de bits**. La velocidad en baudios de una señal representa el número de cambios de estado, o eventos de señalización, que la señal tiene en un segundo. Cada evento de señalización transmitido puede transmitir uno o más bits. Sólo cuando cada evento de señalización transporta un solo bit coincide la velocidad de transmisión de datos en baudios y en bits por segundo.

Velocidad de Transmisión de Datos

La velocidad de transmisión de datos será:

$$V_t = \frac{1}{T} (\log_2 n) = V_m (\log_2 n) \quad (\text{Ecuación 3.37})$$

Dónde: $V_m = \frac{1}{T}$ es la velocidad de Modulación

Solo en el caso de tener dos estados significativos ($n = 2$), el número de baudios coincidirá con la cantidad de bits por segundo que se pueden transmitir por la línea.

Velocidad de Transferencia de datos

En la transmisión de información digital entre computadoras es fundamental que aseguremos intercambios de datos libres de errores. El coste de esto estriba en que a la propia información a transmitir se le deben de añadir otras informaciones adicionales para

detección/corrección de errores, para establecer y controlar la comunicación, etc. Aparece aquí un nuevo concepto de velocidad que llamaremos **velocidad de transferencia de datos**, y que representa la cantidad de información útil que puede transmitirse por unidad de tiempo:

$$V_{td} = \frac{\text{Número de Bits Información Util}}{\text{Tiempos para Transmitir Todos los Bits}} \quad (\text{Ecuación 3.38})$$

Para producir una transmisión de datos con éxito, es esencial que los equipos transmisores trabajen a la misma velocidad.

Unidades de Medida

El **Decibel** es una unidad de medida muy usada en las telecomunicaciones para indicar la relación entre potencias, tensiones o corrientes, en valores relativos o absolutos. Existen diferentes tipos de decibeles, siendo los más característicos los siguientes:

El dB

El dB es una unidad que indica la relación de potencias, tensiones o corrientes entre dos valores conocidos. Es por lo tanto, una unidad de medida relativa, pues no tiene un valor patrón de comparación.

- **Relación de ganancia en dB:** sea un circuito amplificador, como el de la figura 26, definiremos como ganancia de potencia del circuito, (también puede ser de tensión o de corriente) a la relación siguiente:

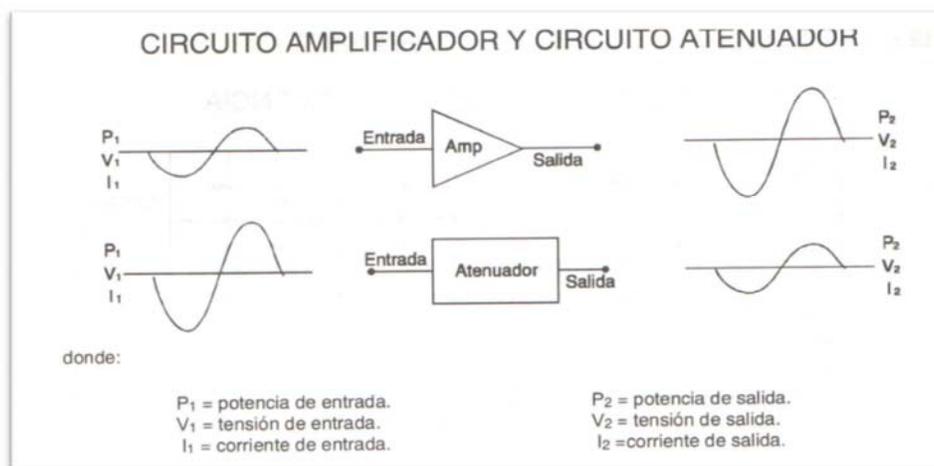


Figura 26. Circuito Amplificador y Circuito Atenuador
Fuente: Internet

$$\text{Relación de potencias } G \text{ (dB)} = 10 \log \frac{P_2}{P_1} \quad (\text{Ecuación 3.39})$$

$$\text{Relación de tensiones } G \text{ (dB)} = 20 \log \frac{V_2}{V_1} \quad (\text{Ecuación 3.40})$$

$$\text{Relación de corrientes } G \text{ (dB)} = 20 \log \frac{I_2}{I_1} \quad (\text{Ecuación 3.41})$$

En el caso de las ecuaciones 3.53 y 3.54, se deben tomar las medidas de entrada y salida sobre la misma impedancia de carga.

- **Relación de Pérdida en dB:** Sea un circuito atenuador, como el de la Figura 26, definiremos como pérdida de potencia del circuito (tensión o corriente) a la relación siguiente:

$$\text{Relación de potencias P (dB)} = 10 \log \frac{P_1}{P_2} \quad (\text{Ecuación 3.42})$$

$$\text{Relación de tensiones P (dB)} = 20 \log \frac{V_1}{V_2} \quad (\text{Ecuación 3.43})$$

$$\text{Relación de corrientes P (dB)} = 20 \log \frac{I_1}{I_2} \quad (\text{Ecuación 3.44})$$

En el caso de las ecuaciones 3.43 y 3.44, se deben tomar las medidas de entrada y salida sobre la misma impedancia de carga.

También hay unas reglas generales para aproximarse a la relación entre los dB y la potencia:

- Un incremento de 3 dB duplica la potencia.
- Una reducción de 3 dB reduce la potencia a la mitad
- Un incremento de 10 dB es igual a 10 veces la potencia
- Una reducción de 10 dB es igual a una décima parte de la potencia

El dbm

A diferencia del dB que es una unidad de medida relativa, el dbm es una unidad de nivel absoluto, que mide la potencia (de salida o de entrada según corresponda, para un circuito amplificador o atenuador), respecto de un valor fijo de 1 mW.

Cuando la comparación se efectúe respecto de valores de potencia por debajo de 1 mW, el resultado será siempre negativo.

$$\text{dbm} = 10 \log \frac{P_i(\text{mW})}{1 \text{ mW}} \quad (\text{Ecuación 3.45})$$

En algunos casos donde se usan potencias mayores, se toma como valor fijo 1 Watt y en ese caso la unidad se denomina dbW.

El dbu

El dbu es una unidad de nivel absoluto usada para comparar tensiones respecto de un valor fijo de 0.775 Voltios.

Esta unidad es muy usada en telefonía y el valor de 0.775 Volt es un valor que resulta, cuando sobre una impedancia de 600 ohms, se aplica una potencia de 1 m Watt.

$$\text{dbu} = 20 \log \frac{V_i(\text{V})}{0.775 \text{ V}} \quad (\text{Ecuación 3.46})$$

El dbmv

El dbmv es una unidad de nivel absoluto, usada para comparar tensiones respecto de un valor fijo de 1 mV.

$$\text{dbmv} = 20 \log \frac{V_i \text{ mV}}{1 \text{ mV}} \quad (\text{Ecuación 3.47})$$

El Neper

El Neper es una unidad relativa usada como alternativa del dB. La diferencia con este, radica en que la base de los logaritmos usados es el número e, en lugar de la base 10, usada por aquella otra unidad de medida.

$$\text{Neper (N)} = \frac{1}{2} \ln_e \frac{P_2}{P_1} \quad (\text{Ecuación 3.48})$$

3.5. Eficiencia del Ancho de Banda en el Espectro Radio Eléctrico

El principal objetivo de todo mecanismo de gestión del espectro es, alcanzar la mayor eficiencia posible en su uso. Así, por ejemplo, cualquier nueva propuesta para una posible introducción de mecanismos de flexibilización del uso del espectro radioeléctrico tiene como fin la mejora de la eficiencia en la gestión y, consecuentemente, en el uso del espectro.

Eficiencia.

Para analizar este concepto es preciso tener en cuenta que el espectro es un bien de dominio público finito o limitado, cuya titularidad, gestión, planificación, administración y control corresponde al Estado, que es el que debe garantizar el mayor beneficio posible para los ciudadanos, derivado del uso de ese bien público.

Para ello, entre los fines que se persiguen en la gestión del espectro, suelen citarse el garantizar su uso eficiente, promover su uso como factor de desarrollo económico, favorecer el desarrollo y la innovación, permitir a todos los ciudadanos el acceso a los servicios que hagan uso del espectro, permitir la planificación estratégica del sector de las telecomunicaciones, etc.

Los anteriores fines se pueden englobar en tres dimensiones de eficiencia, que constituirán, globalmente, la definición de la eficiencia genérica en el uso del espectro: eficiencia técnica, eficiencia social y eficiencia económica.

Eficiencia técnica

En la asignación del espectro se traduce en que el mayor número posible de frecuencias esté disponible para ser utilizado de manera efectiva en la prestación de servicios, limitando, en la medida de lo técnicamente viable, las bandas de guarda o la existencia de bandas de frecuencias en las que las interferencias entre distintas señales radioeléctricas hagan imposible un aprovechamiento real de dicho espectro. Mediante esta maximización del espectro disponible se consigue que un mayor número de agentes sean capaces de acceder a este recurso.

Eficiencia social

Implica que el uso de este recurso debe caracterizarse por favorecer el desarrollo social, permitiendo el acceso de los ciudadanos a una diversa oferta de servicios que les ofrezcan nuevas o mayores facilidades, como podría ser el acceso de banda ancha en zonas rurales; como en nuestro caso la Amazonia Peruana; mediante tecnologías inalámbricas o, como otro ejemplo, una mayor diversidad de contenidos de interés gracias a los nuevos canales de televisión digital.

Eficiencia económica

En la asignación del espectro es aquella que, una vez alcanzada, hace que ningún agente tenga incentivos para cambiar de asignación. Esto se puede conseguir cuando el uso que se dé al mismo sea el que garantice un mayor desarrollo económico (eficiencia dinámica).

La distribución del espectro en el país para el rango de frecuencias de 9KHz hasta 300GHz está contemplada en el Plan Nacional de Frecuencias (PNAF) aprobado por el Ministerio de Transportes y Comunicaciones.

Este documento comprende la atribución de bandas de frecuencia para todos los servicios brindados a través del espectro radioeléctrico; sin embargo, la rápida evolución y aparición de nuevas tecnologías han hecho que la actual distribución de este recurso resulte deficiente, ya que aún no permite el despliegue de redes 4G en las grandes ciudades y 2G y 3G en la de menor población a nivel nacional y porque se necesita una redistribución progresiva para la implementación de la televisión digital terrestre.

En el Tabla 8 que se muestra a continuación se muestra un resumen del espectro radioeléctrico con la descripción de sus principales características de propagación y usos típicos según el rango de frecuencia.¹²

RANGOS DE FRECUENCIA DEL ESPECTRO Y SUS CARACTERÍSTICAS PRINCIPALES

CLASE	RANGO DE FRECUENCIA	LONGITUD DE ONDA (λ)	CLASIFICACIÓN UIT	CARACTERÍSTICAS DE PROPAGACIÓN	USOS TÍPICOS
VLF	(9 - 30) KHz	(30 - 10) Km	Miriamétricas	Baja atenuación a toda hora y durante todo el año	Comunicaciones de banda angosta a larga distancia. Señales horarias.
LF	(30 - 300) KHz	(10 - 1) Km	Kilométricas	De noche similar a VLF, varía durante el día	Sistemas de ayuda a la navegación, comunicaciones marítimas.
MF	(300 - 3000) KHz	(1000 - 100) m	Hectométricas	Baja atenuación durante la noche, alta durante el día	Radiodifusión, comunicaciones marítimas.
HF	(3 - 30) MHz	(100 - 10) m	Decamétricas	Depende sólo de la ionósfera	Comunicaciones de todo tipo a distancias medias y largas.
VHF	(30 - 300) MHz	(10 - 1) m	Métricas	Propagación Rectilínea	Comunicación a corta distancia. TV. FM. Radar. Navegación aérea.
UHF	(300 - 3000) MHz	(100 - 10) cm	Decimétricas	Ídem	TV. Radar. Sistemas relevadores para comunicaciones a larga distancia.
SHF	(3 - 30) GHz	(10 - 1) cm	Centimétricas	Ídem	Radar, microondas, radionavegación, comunicaciones especiales.
EHF	(30 - 300) GHz	(10 - 1) mm	Milimétricas	Ídem	Ídem

Tabla 8. Rangos de Frecuencia del Espectro y sus Características Principales

Fuente: Internet

¹²http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/938/CARRILLO_PALOMINO_SARA_ADMINISTRACION_ESPECTRO_RADIOELECTRICO.pdf?sequence=1

En la siguiente figura 27 se muestra la distribución de las bandas de frecuencia para los servicios públicos, es importante observar la gran cantidad de bandas libres que deben ser estudiadas para su posible uso en la implementación de nuevas tecnologías, además la mayoría de bandas están atribuidas a Servicios de Acceso Fijo Inalámbrico como son los ofrecidos por empresas de telefonía móvil.¹³

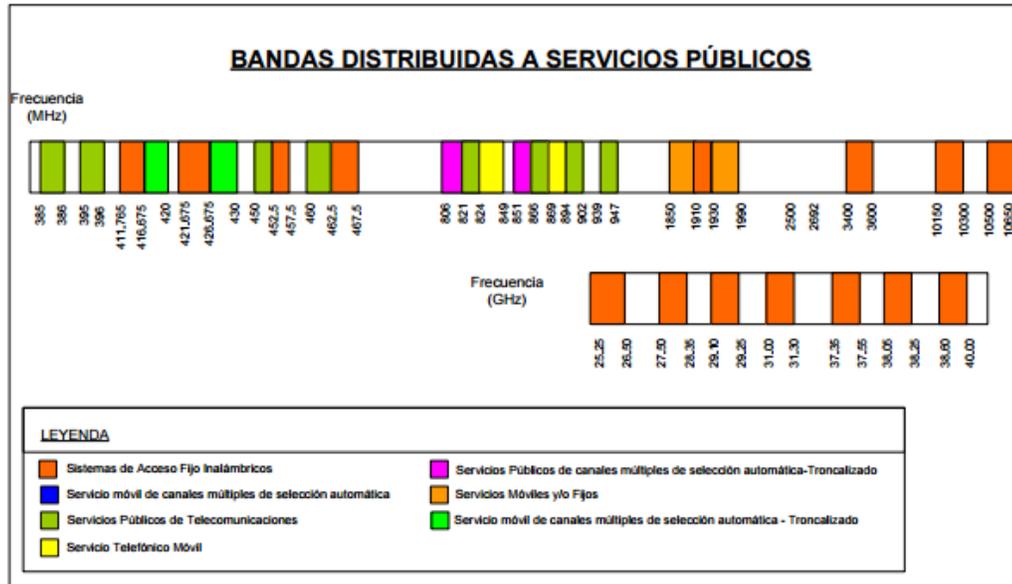


Figura 27. Bandas Distribuidas a Servicios Publico

Fuente: Internet

La eficiencia en el uso y explotación del espectro radioeléctrico debe estar orientada a otorgar el máximo beneficio a los usuarios del mismo y al menor costo posible, atendiendo sus necesidades de demanda, cobertura, calidad y servicios, lo cual descansa primordialmente en el diseño de las redes y la tecnología que éstas emplean para la gestión de los recursos espectrales.

Podemos encontrar en la literatura enfocada a la definición de eficiencia espectral, otra definición de uso eficiente del espectro orientada a sistemas digitales, la cual se refiere a la cantidad de información por segundo (bits/s o bps) que se pueden transmitir por cada Hz de ancho de banda disponible con la menor cantidad de errores (E), misma que se expresa en bps/Hz (bits/segundo/Hertz); y cuya expresión matemática simple es:

$$E = R / B$$

Donde:

R : es la tasa de transmisión en bps (bits/s).

B : es el ancho de banda utilizado del canal.

De igual forma, existen diversas referencias que se enfocan a definir la eficiencia espectral en redes con configuración celular, con base en el máximo número de usuarios por celda que pueden ser atendidos manteniendo un nivel aceptable de calidad de servicio (QoS).

¹³http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/938/CARRILLO_PALOMINO_SARA_A_DMINISTRACION_ESPECTRO_RADIOELECTRICO.pdf?sequence=1

En este sentido habría que considerar los tipos de servicios a prestarse, los cuales, considerando una clasificación genérica podrían ser: voz (a una tasa de 64 kbps), datos y video, estos dos últimos con tasas de transferencia variable dependiendo de la calidad contratada, o una combinación de ellos.

A manera de ejemplo, consideremos un servicio básico de voz, el cual requiere de un ancho de banda de 64 kHz asumiendo una eficiencia espectral de 1 bps por Hertz. En este sentido, en un sector de una celda con una portadora de ancho de banda de 30 MHz podrían atenderse un promedio de 468 usuarios ($30,000,000 / 64,000$) realizando llamadas de voz de manera simultánea. Un esquema de análisis similar podría aplicarse para el caso de la oferta de servicios de datos y video, en los cuales la tasa de transferencia de datos es variable y dependerá básicamente del servicio contratado, lo que impacta directamente en el número de usuarios que pueden ser atendidos por una celda de la red o un sector de la celda.

Como puede observarse, desde un punto de vista técnico el concepto de eficiencia espectral puede ser variable, ya que el mismo puede encontrarse referenciado a elementos geográficos, tiempo de uso, de la cantidad de información a ser transmitida y por supuesto de la cantidad de usuarios que pueden ser atendidos.

Por otro lado, el uso óptimo de un recurso escaso requiere más que una consideración de eficacia puramente técnica, ya que se deben conocer las necesidades por parte de los usuarios para encontrar la forma más eficiente y eficaz posible para su aprovechamiento y de esta forma considerar las coacciones económicas, funcionales y técnicas que se aplican en cada uno de los diferentes servicios. No obstante, la evaluación de estos aspectos necesita además de un grado alto de valoración cuantitativa, una buena porción de juicio cualitativo, el cual debe estar orientado por la política pública que defina la autoridad correspondiente.

En este sentido y en virtud de la inexistencia de un mecanismo establecido y probado para determinar el grado en que una banda de frecuencias es utilizada de manera eficiente, resulta necesario realizar una investigación minuciosa sobre las referencias y tendencias globales provenientes de organismos internacionales, organizaciones de desarrollo tecnológico y entidades reguladoras, orientadas a definir mecanismos y métodos empleados para la determinación de un parámetro de eficiencia espectral.

Con esa información, se buscaría definir un parámetro o métrica propios que determinen la eficiencia espectral en función de los aspectos relevantes en la prestación de servicios inalámbricos, tales como: banda de frecuencias, ancho de banda, tecnologías disponibles, cantidad de usuarios a servir, cobertura territorial, métodos de modulación, tipo de duplexaje y situación competitiva, entre otros.

3.6. Plan de Frecuencia del Espectro Radioeléctrico

El espectro radioeléctrico es un recurso natural conformado por el conjunto de ondas electromagnéticas cuyas frecuencias se fijan convencionalmente desde 9 kHz hasta 300 GHz y que forma parte del patrimonio de la Nación. El Estado es soberano en su aprovechamiento, correspondiendo su gestión, administración y control al Ministerio de Transportes y Comunicaciones.

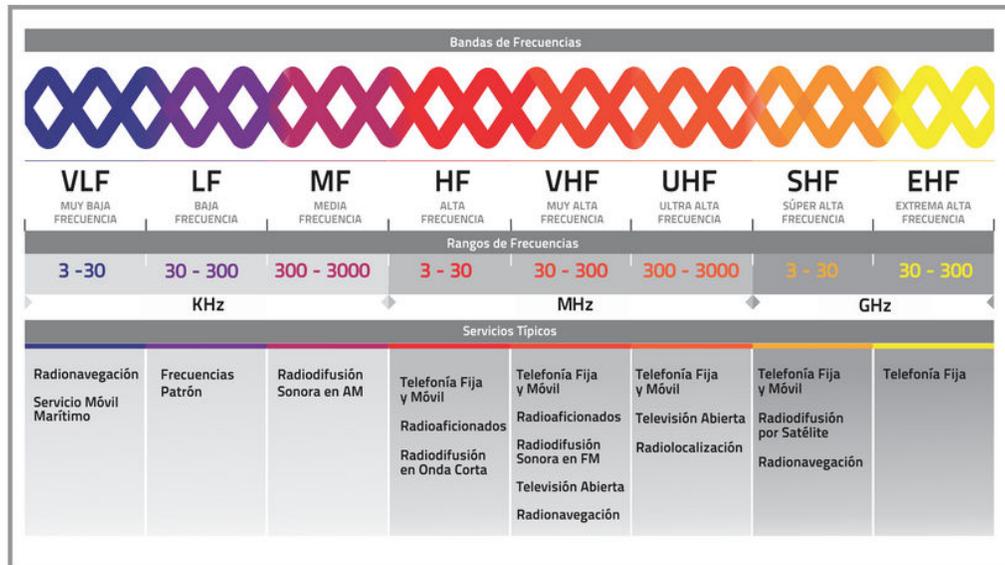


Figura 28. Bandas de Frecuencia

Fuente: Internet

El **Plan Nacional de Atribución de Frecuencias (PNAF)** contiene los cuadros de atribución de frecuencias de los diferentes servicios de telecomunicaciones en la República del Perú, de tal forma que los diversos servicios operen en bandas de frecuencias definidas previamente para cada uno de ellos, a fin de asegurar su operatividad, minimizar la probabilidad de interferencias perjudiciales y permitir la coexistencia de servicios dentro de una misma banda de frecuencias, cuando sea el caso.

Por la naturaleza dinámica de la gestión de frecuencias, el PNAF debe actualizarse periódicamente como resultado de acuerdos tomados en las Conferencias Mundiales de Radiocomunicaciones de la **Unión Internacional de Telecomunicaciones (UIT)**, acuerdos bilaterales y multilaterales celebrados con otras Administraciones, recomendaciones formuladas por organismos internacionales de los que el Perú es miembro como la **Comisión Interamericana de Telecomunicaciones (CITEL)** y de aquellas modificaciones, adiciones o expedición de normas nacionales, aplicadas a los planes de distribución de radiocanales de los servicios de radiocomunicación que actualmente están en operación, o bien de los nuevos servicios de radiocomunicación¹⁴.

La gestión y planificación del espectro radioeléctrico se realiza en tres etapas.

En una etapa inicial, el MTC, el Osiptel y algunos operadores participan en la planificación de atribución de frecuencias, para ello se llevan a cabo reuniones de trabajo con las empresas y consultas públicas.

Luego se inicia el proceso de asignaciones y concesiones sobre la base de lo que se ha estipulado en el PNAF.

En ese momento interviene la Agencia de Promoción de la Inversión Privada en el Perú (Pro-Inversión) para la elaboración de los concursos públicos.

¹⁴ http://transparencia.mtc.gob.pe/idm_docs/normas_legales/1_0_115.pdf. pp 5

Finalmente, luego de que el operador recibe la licencia, el MTC y el Osiptel deben cumplir determinadas funciones de monitoreo y evaluación. Este proceso se ve puede observar en el gráfico siguiente¹⁵:

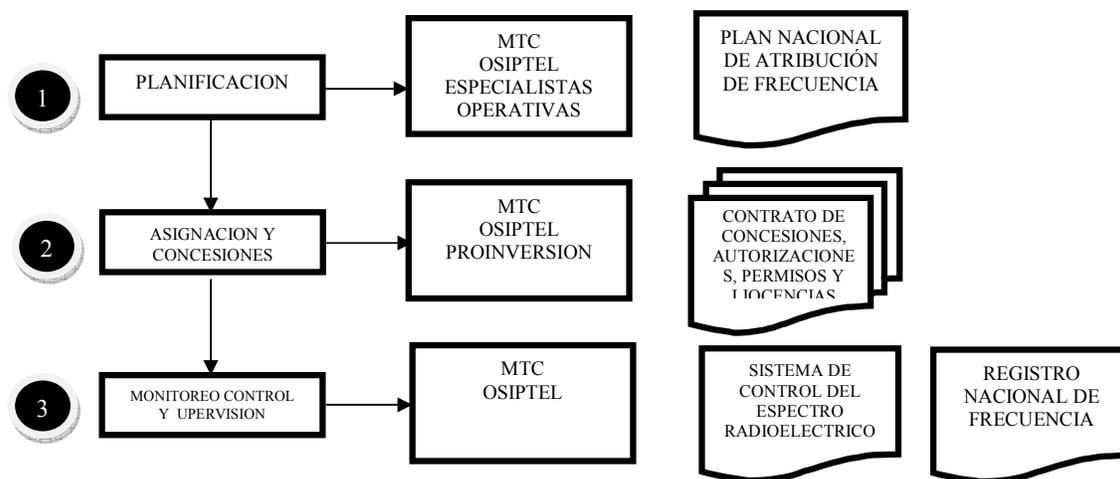


Figura 29. Etapas de gestión y planificación del espectro radioeléctrico
Fuente: Elaboración propia

Acceso a internet

El acceso y uso de internet en el Perú ha tenido un incremento significativo en los últimos años.

El Instituto Nacional de Estadística e Informática (INEI) dio a conocer que en el trimestre enero-febrero-marzo del presente 2014 año, de cada 100 hogares 89 tiene al menos un equipo de la Tecnología de Información y Comunicación (teléfono fijo, teléfono móvil, televisión por cable, Internet o computadora), lo que representó un crecimiento de 1,7 puntos porcentuales, en comparación con similar trimestre de 2013.

De acuerdo con Informe Técnico *Estadísticas de las Tecnologías de Información y Comunicación en los Hogares*, trimestre enero-febrero-marzo de 2014, elaborado con los resultados de la Encuesta Nacional de Hogares, el mayor incremento se registró en los hogares cuyos jefes cuentan con educación primaria o menor nivel en 3,2 puntos porcentuales, seguido por los que tienen educación secundaria en 2,4 puntos porcentuales; lo que se explica ya que los hogares con jefes que tienen educación superior no universitaria y universitaria registraron coberturas de 98,1% y 98,9%, respectivamente; lo que determina que su crecimiento porcentual sea mínimo.

Se incrementa acceso de hogares rurales a telefonía móvil: En todos los hogares del país se incrementó el acceso al servicio de telefonía móvil, registrándose el mayor crecimiento en los hogares del área rural en 6,0 puntos porcentuales (de 61,8% a 67,8%), seguido del resto urbano en 2,4 puntos porcentuales (87,4% a 89,8%) y en Lima Metropolitana en 2,2 puntos porcentuales (de 88,5% a 90,7%).

¹⁵ Espectro abierto para el desarrollo Estudio de caso: Perú Maicu Alvarado y Gabriela Perona
Centro Peruano de Estudios Sociales – CEPES Asociación para el Progreso de las Comunicaciones
Noviembre 2011. Pp 20

A nivel nacional, el acceso a este servicio alcanza al 84,6% de hogares, lo que representó un crecimiento de 3,1 puntos porcentuales, respecto al primer trimestre del año pasado (81,5%).

A nivel nacional creció el acceso al servicio de televisión por cable: El servicio de televisión por cable aumentó en todos los hogares del país en 2,9 puntos porcentuales al pasar de 37,7% en el primer trimestre de 2013 a 40,6% en el trimestre de 2014.

Según área de residencia, el mayor incremento se observó en Lima Metropolitana al pasar 58,8% a 64,1%, lo que significa un incremento de 5,3 puntos porcentuales, respecto al primer trimestre de 2013. En el resto urbano (no incluye Lima Metropolitana) y en el área rural el acceso a telefonía móvil presentó coberturas de 42,0% y 9,0% de los hogares, respectivamente; con crecimientos de 2,8 y 1,7 puntos porcentuales, para cada caso.

Aumentan hogares que tienen dos tipos de telefonía: En el primer trimestre del presente año, el porcentaje de hogares del país que cuentan con telefonía fija y móvil se incrementó en 1,8 puntos porcentuales, al pasar de 29,0% a 30,8%. Por otro lado, disminuyó en 1,6 puntos porcentuales los hogares que no disponen de estas tecnologías de Información y Comunicación.

En 2,6 puntos porcentuales aumentan hogares del área rural que tienen televisor: En el primer trimestre del presente año, se incrementó en 2,6 puntos porcentuales los hogares del ámbito rural que tiene televisor al pasar de 50,1% a 52,7%. En cambio, disminuyeron los hogares que tienen aparato de radio en 1,9 puntos porcentuales al bajar de 79,7% a 77,8%.

De cada 100 hogares del país 37 tiene al menos una computadora: En el trimestre de análisis, de cada 100 hogares 37 tienen al menos una computadora, lo que representó un crecimiento de 2,4 puntos porcentuales. Por área de residencia, el 54,6% de los hogares de Lima Metropolitana disponen por lo menos de una computadora, en el Resto urbano el 43,1% y el 7,0% de los hogares rurales.

Cerca del 50% de los hogares de Lima Metropolitana tienen servicio de Internet: El 49,5% de los hogares de Lima Metropolitana tienen servicio de Internet lo que significó un incremento de 5,4 puntos porcentuales, respecto a primer trimestre de 2013; mientras que en el Resto Urbano y el área rural presentaron coberturas de 27,1% y 0,8%, respectivamente; con incrementos de 1,2 y 0,2 puntos porcentuales en cada caso.

Población de 12 a 24 años son los mayores usuarios de Internet: El 69,0% de la población de 19 a 24 años de edad y el 55,0% de la población de 12 a 18 años de edad son los mayores usuarios de internet; seguido del 31,0% de los niños de 6 a 11 años. A su vez, el 11,0 % de la población adulta mayor (de 60 y más años de edad) usa Internet.

Acceso a internet está asociado a mayor nivel de educación: En el trimestre de análisis, el 84,8% de la población con nivel de educación superior universitaria y el 63,0% con superior no universitaria son los mayores usuarios de Internet. Por el contrario, el 14,9% de la población con educación primaria o menor nivel accede a este servicio.

Se incrementa el uso diario de Internet: En el trimestre enero-febrero-marzo del presente año, se incrementó en 3,8 puntos porcentuales la población que hace uso diario

de Internet, al pasar de 48,9% a 52,7%. Según sexo, el 52,6% de la población masculina y el 52,8% de la población femenina acceden a Internet una vez al día, habiéndose incrementado en 3,0 y 4,7 puntos porcentuales, respectivamente.

Plan nacional para el desarrollo de la banda ancha (PNDBA)

El Plan nacional para el desarrollo de la banda ancha en el Perú⁴ se está implementando desde principios del año 2011. El principal problema identificado por el grupo de trabajo del Ministerio de Transportes y Comunicaciones que elaboró el PNDBA es la existencia de una gran brecha de acceso entre las ciudades de la costa y el interior del país. Según los estudios realizados, la banda ancha en el Perú, alcanzó "... a marzo de 2011 una teledensidad de 4.39% con un total de 1'304,065 conexiones a nivel nacional, habiendo registrado un 222.5% de crecimiento respecto de junio de 2006. Asimismo, en relación a las tecnologías de acceso empleadas, tenemos que el 76% del total de conexiones se prestan a través de la Banda Ancha fija y el 24% a través de la Banda Ancha móvil".

Cabe destacar que, según el estudio realizado para el Diálogo Regional sobre Sociedad de la Información (DIRSI), la calidad de la banda ancha fija en América latina y el Caribe sigue siendo baja y de altos precios. El informe revela que en promedio la oferta de banda ancha fija de los países de la región no supera los 2 Mbps, siendo el Perú el cuarto país con menor calidad de banda ancha fija de los países sudamericanos¹⁶.

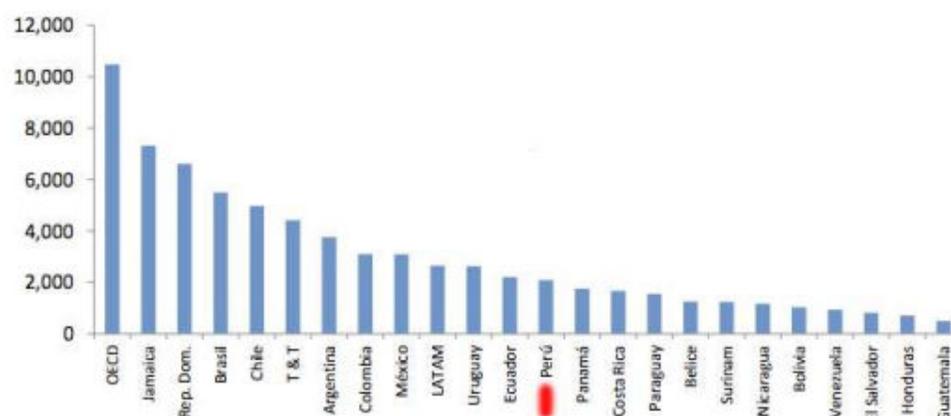


Figura 30. Calidad de la Banda Ancha en América Latina y el Caribe

Fuente: Internet

El PNDBA del Estado peruano desarrolla un análisis de la situación del espectro radioeléctrico, en el que se incluye la sistematización de bandas potenciales para el despliegue de la banda ancha, las concesiones que existen sobre ellas y da recomendaciones para una distribución de frecuencias dirigida hacia este servicio.

El PNDBA ha tomado en cuenta la expansión presente y futura de la telefonía móvil, a nivel de acceso y uso. Sobre la base de este documento se observa que la política de banda ancha se perfila hacia el acceso móvil. Se considera que esta es la tendencia en la región y de acuerdo al estudio realizado antes citado, en el cual se hace una comparación entre

¹⁶ Espectro abierto para el desarrollo Estudio de caso: Perú Maicu Alvarado y Gabriela Perona
Centro Peruano de Estudios Sociales – CEPES Asociación para el Progreso de las Comunicaciones
Noviembre 2011. Pp 5

planes de banda ancha fija y móvil, esta última resulta 25% más barata que la fija, lo que permite un despliegue mayor del servicio.

En esta perspectiva, el diagnóstico elaborado para el PNDBA ha planteado algunas barreras actuales para el despliegue de la banda ancha móvil en relación a las limitaciones de uso del espectro radioeléctrico por los operadores móviles.

El PNDBA muestra que el Perú debe disponer de infraestructura y oferta de servicios adecuados para el desarrollo de la banda ancha a nivel nacional, así como implementar políticas, planes y proyectos que estimulen la demanda y la inclusión de la población en la Sociedad de la Información. Se han establecido como metas específicas al 2016:

- 100% de centros educativos, establecimientos de salud, comisarías y otras entidades del Estado, en zonas urbanas cuenta con conexiones de banda ancha, a una velocidad mínima de 2 Mbps.
- 100% de los distritos del Perú cuenta con cobertura de banda ancha que como mínimo conecta a la municipalidad, a los centros educativos y establecimientos de salud públicos de mayor envergadura del distrito, a una velocidad mínima de 2 Mbps.
- Alcanzar los cuatro millones de conexiones de banda ancha a nivel nacional.
- Alcanzar el medio millón de conexiones de banda ancha de alta velocidad, mayores a 4 Mbps.

3.7. Tipo de Soluciones para la Optimización del Consumo de Ancho de Banda

Las soluciones indicadas a continuación se deben tomar como un conjunto de medidas o buenas prácticas que optimicen el consumo de ancho de banda en el uso de Internet y que minimicen el coste de las mismas en las instituciones públicas y de manera particular a la Universidad Nacional de la amazonia Peruana UNAP, pero con posibilidades de aplicar en otras instituciones públicas.

Directrices de normalización del uso de internet

Como primera medida a tomar en toda institución pública, debe considerarse la aprobación, actualización y revisión de Directrices que incluyen Políticas, Procedimientos e Instructivas para el uso de la red y sus servicios o prestaciones. La Política consistirá en un primer grupo de nivel general de los aspectos a regular en una red y deberá estar acompañada de un conjunto de procedimientos e instructivas que nos aseguran que pueda ser puesta en práctica.

Las directrices deberán tomar en cuenta aspectos cómo:

- a) Una lista de dominios no autorizados, conocidos por su transmisión de troyanos, virus, phishing, etc.
- b) Horarios para la navegación de sitios que no son de interés para la misión de la institución y que presenten tráfico elevado en las instituciones.
- c) Requisitos mínimos de seguridad que debe tener un equipo conectado a la red.

Esto apuntaría a un reglamento de coexistencia con fines de ahorrar ancho de banda y maximizar el uso de los enlaces. Sin embargo, existen estándares internacionales utilizados para la construcción de políticas de uso, siempre y cuando los mismos sean adaptados a las realidades de cada institución.

Determinación de tráfico crítico o indispensable

Una de las medidas más comunes y efectivas para la optimización del tráfico hacia y desde un enlace de una institución es el mecanismo conocido como QoS (por su definición en inglés: Quality of Service o calidad de servicio). A través de un estudio de caracterización de tráfico se podrán definir en nuestras instituciones qué tipo de tráfico queremos asegurar y aplicar mecanismos de calidad de servicio que garanticen que el tráfico crítico no sufra intermitencias, pérdidas de paquetes o lentitud en la transmisión.

La determinación del tráfico en el ancho de banda dentro del espectro radioeléctrico en un determinado tiempo es importante para identificar la demanda real y proyectar a partir de ello los contratos del servicio, optimizando de esta manera e la utilización de un ancho de banda real acorde al consumo y optimizando también el costo efectivo por el servicio.

Normalización y difusión del uso de herramientas como servidores ftp, repositorios y wsus

Al proveer en nuestras instituciones mecanismos como FTP y WSUS estaremos asegurando que todas aquellas actualizaciones de software, bien sea para sistema operativo o aplicaciones, sean realizadas de forma interna.

Normalización y difusión del uso de herramientas que permiten el intercambio de archivos de tamaño considerable

Está demostrado que el crecimiento de uso de herramienta de intercambio de archivos vía web ha crecido abrumadoramente. El acceso a sitios web como megaupload, rapidshare o cualquier otra con servicios similares, desde las instituciones públicas ha ido aumentando. En estos sitios pueden colocarse desde archivos de texto hasta fragmentos de películas que luego se acoplan en el equipo del usuario para formar el vídeo completo. Muchas veces los pares o usuarios que comparten esta información pueden estar incluso dentro de una misma institución por lo cual el uso de herramientas o Apps podrían ayudar a ahorrar ancho de banda al momento de compartir un archivo entre pares de la misma institución.

Definición de cuotas máximas por host

Esta es una buena práctica que se inicio con los permisos de acceso acorde a los perfiles de los usuarios de una red LAN, en esta oportunidad esta medida se ha generalizado al control de los tiempos de acceso a los HOST de alojamiento y acceso de internet, en una revisión exhaustiva realizada a instituciones universitarias se pudo encontrar que la situación de saturación de enlaces hacia Internet no es exclusiva de la UNAP. En varias de las instituciones revisadas una de las soluciones propuesta fue la de analizar por medio de caracterizaciones de tráfico la cantidad promedio de consumo de un host hacia Internet. De allí se definió una cuota máxima de bytes que se le permitirá a un equipo por día para navegar, descargar, etc. en horario laboral. Al momento de exceder esta cuota el usuario perdería su conexión a Internet. Las causas por las cuales los usuarios excedan sus cuotas pueden ser variadas y deberán ser analizadas en cada caso para no impedir en ningún caso el normal desempeño y productividad de los miembros de la institución.

Educación de los usuarios de la institución

A través de talleres de cómo ahorrar ancho de banda (pueden ser correos informativos, blogs, vídeos y presentaciones) se podrá explicar a los miembros de las instituciones las medidas que deben tomarse para disminuir el ancho de banda que usa. Así

como las medidas mínimas de seguridad que debe tener al momento de conectar un equipo a la red. En muchos casos, al menos en el entorno de la UNAP, podemos observar grandes cantidades de tráfico emitidos por equipos que poseen configuraciones por omisión que pueden generar tráfico anómalo e innecesario para el funcionamiento de sus equipos, que a su vez puede generar lentitud en sus equipos y entorpecer así sus labores.

Implementar campus virtuales entre instituciones universitarias para asegurar que el tráfico académico esté viajando por éstos enlaces.

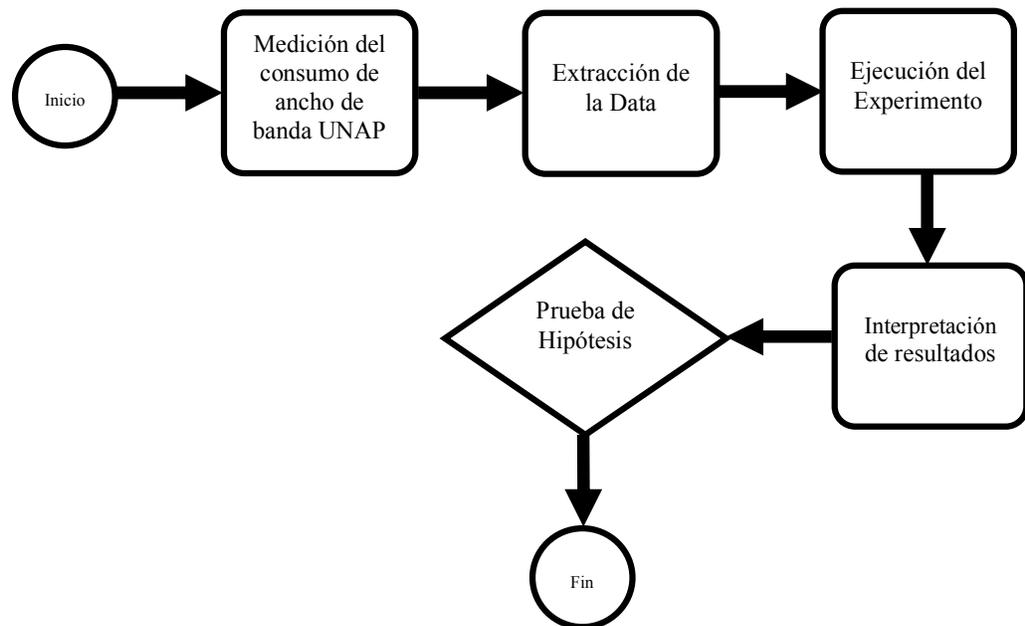
La introducción del enlace académico en instituciones universitarias ha será un paso muy importante hacia el ahorro del uso de los enlaces a Internet comercial. Esto garantizaría la fluidez del tráfico a través de una red por la cual los investigadores, académicos y estudiantes de la comunidad universitaria pueden desarrollar actividades cómo videoconferencias, consultas de repositorios académicas, descargas de software académico, etc.

Capítulo 4 Solución propuesta

4.1. Descripción

El modelo de la solución propuesta consiste establecer ciertos procedimientos sistemáticamente ordenados para resolver el problema general planteado¹⁷:

- Medición del consumo de ancho de banda en el espectro radioeléctrico.
- Extracción y validación de la data obtenida en el proceso anterior.
- Ejecución de experimento aplicando redes neuronales.
- Interpretación de resultados.
- Prueba de hipótesis.



*Figura 31. Modelo de solución
Fuente: Elaboración propia*

¹⁷ Pronostico de consumo de ancho de banda utilizando redes neuronales en una empresa de tecnologías de información. Pp 40

En la figura se observa el proceso de solución del problema plateando aplicando redes neuronales para la optimización y predicción del ancho de banda de internet de la UNAP en un periodo dado.

Como actividad previa al inicio del modelo de solución con redes neuronales se deben preparar los datos, ya que un ingreso directo de los mismos generaría un error muy grande en el resultado y arruinar la solución propuesta.

- Medición del consumo de ancho de banda: Se logra con la aplicación de software especializado en monitoreo del espectro radioeléctrico como el NetFlowAnalyzer.
- Extracción y validación de la data obtenida en el proceso anterior: se deberá depurar los datos erróneos, la redundancia y las inconsistencias; con el fin de obtener una información consistente y libre de vicios ocultos.
- Ejecución de experimento aplicando redes neuronales: Se ejecuta los algoritmos de optimización y predicción.
- Interpretación de resultados : Se calcula el MAPE y los indicadores de desempeño.
- Prueba de hipótesis: se realiza la consistencia de la prueba de hipótesis con la información estadística.

4.2. Aplicación del Software de Recolección de Datos: Netflowanalyzer

El software NetFlowAnalyzer es un aplicativo web que monitorea el tráfico de paquetes de datos en una red de datos, de acuerdo a su ubicación puede monitorear el tráfico del acceso a internet en un determinado periodo.

Así como NetFlowAnalyzer, existen muchas aplicaciones con similares características, como por ejemplo Endian Firewall Community, Fortinet, PRTG Network Monitor o SolarWinds; siendo su principal característica la del monitoreo del tráfico de una red de datos y las diferentes vulnerabilidades que se pueden suscitar tanto internas como externas.

Selección de la data

Corresponde seleccionar la data con la cual se va a trabajar, las mismas que serán obtenidas por el software de monitoreo bajo ciertos requisitos:

- Periodo de tiempo: 3 meses.
- Inicio: Febrero 2015
- Fin: Abril 2015

Limpieza de la data

Una vez obtenida la data, se debe ejecutar un algoritmo de limpieza, que consiste en identificar y corregir los datos inconsistentes erróneos u anómalos de la base de datos.

Se necesitan cuatro (04) validaciones para poder limpiar la data; Análisis de valores vacíos; análisis de redundancia, análisis de valores atípicos (outliers) y análisis de ruidos.

Análisis de valores vacíos

Se desarrolla el algoritmo para analizar si las observaciones tienen en el atributo consumo de ancho de banda valores nulos para lo cual se aplicara el siguiente método:

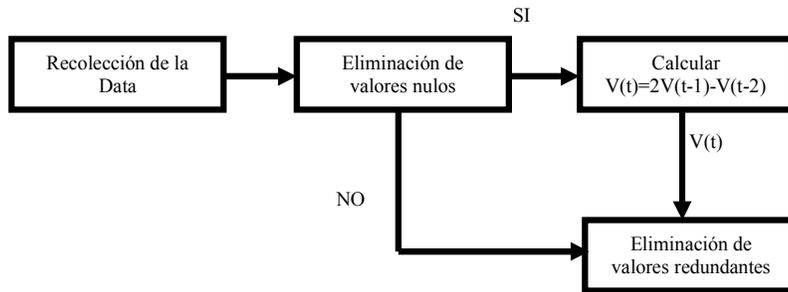


Figura 32. Eliminación de vacios
Fuente: Elaboración Propia

Eliminación de redundantes

Se desarrolla el algoritmo para verificar si las observaciones tienen el mismo valor en todos sus atributos, como fecha, día, hora etc.

En caso de dos o más observaciones que tienen diferentes valores de consumo de ancho de banda pero igual valores en los demás atributos se procederá a calcular el promedio para una y se elimina el resto.

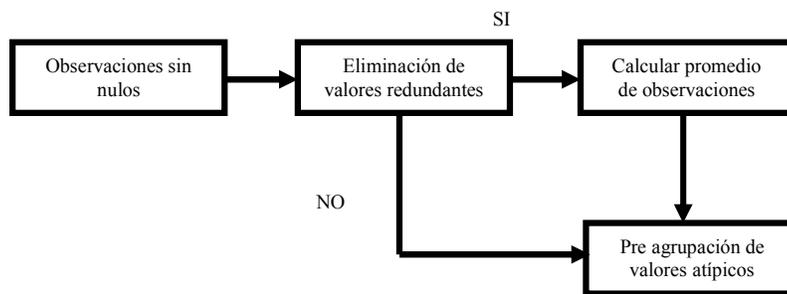


Figura 33. Eliminación de redundantes
Fuente: Elaboración Propia

Análisis de Valores Atípicos (Outliers)

Se desarrolla el algoritmo para analizar las observaciones que pueden presentar outliers para ser remplazado por el promedio de consumo de ancho de banda del día de análisis.

Análisis de Ruidos

Se desarrolla el algoritmo para analizar las observaciones que presenten ruido, las cuales se determinaran al no pertenecer a la tendencia de las observaciones que formaran parte para el cálculo de los objetos de la investigación. Para lo cual se utilizara una regresión simple para poder escoger el valor a remplazar en la observación.

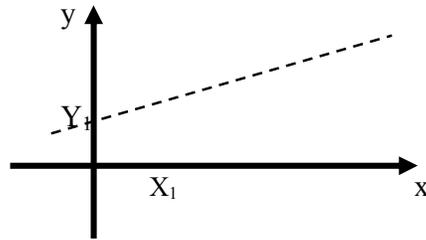


Figura 34. Grafico de ruidos suaves
Fuente: Elaboración propia

4.3. Conversión de Datos en Información

La conversión de los datos en información tiene como tarea inicial la limpieza de la data obtenida del software de monitoreo de ancho de banda¹⁸.

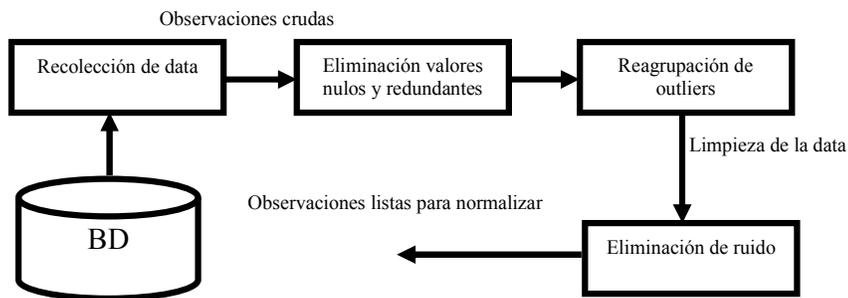


Figura 35. Transformación de datos
Fuente: Elaboración propia

Prototipo de la red neuronal

Esta transformación se realiza aplicando la técnica de redes neuronales al conjunto de datos previamente procesados.

La información se considera al consumo de ancho de banda así como las variables del experimento estas variables normalizadas son la entrada de un modelo de predicción el cual llevaría acabo la transformación de esta información en conocimiento. Esta transformación consiste en predecir el valor de una variable dependiente basándose en los valores de un conjunto de variables independientes y el objeto de estudio.

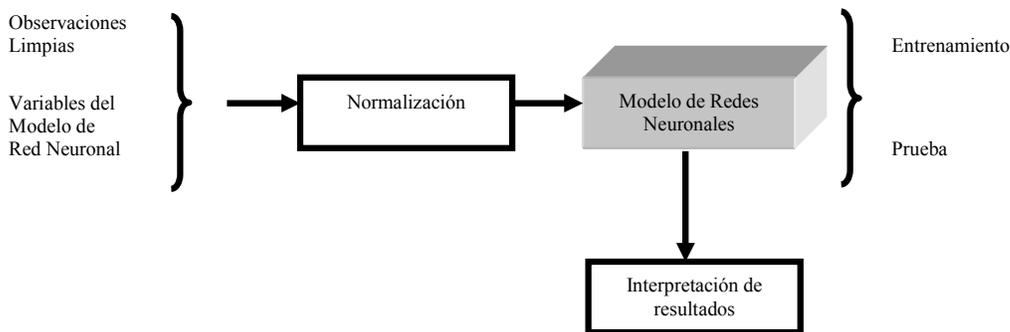


Figura 36. Prototipo de la red neurona
Fuente: Elaboración propia

¹⁸ Pronostico de consumo de ancho de banda utilizando redes neuronales en una empresa de tecnologías de informacion. Pp 43

En Esta etapa la data va ser tratada aplicando dos (02) técnicas de redes neuronales, Retropropagación y Levenberg-Marquardt. Es importante recalcar que un grupo de data va ser utilizado para el entrenamiento a la red, y el resto se va a usar para hallar los pronósticos del ancho de banda.

Los pasos que involucran esta etapa son: Normalización de la data, fase de entrenamiento y fase de prueba.

Normalización de la data

Luego de seleccionar la data, se realiza la normalización utilizando la siguiente ecuación para todos los objetos de estudio:

$$Vi'=(vi-Vmin)/(Vmax-Vmin)$$

Fase de entrenamiento

Se trata del ajuste de los pesos de las conexiones de la red, estos pesos simulan la sinapsis o conexiones entre las neuronas del cerebro.

Para esta actividad se utilizaran dos (02) redes neuronales Retropropagación y Levenberg-Marquardt, las cuales tendrán un numero de iteraciones y número de capas intermedias definidas previamente, los cuales serán simulados para entrenamiento en el aplicativo matlab.

Fase de prueba

Se somete a la red a una variable de vectores de entrada las cuales son determinadas por el parámetro h que es el porcentaje de objetos de estudio de la muestra que formaran parte de la fase de prueba.

Se utiliza la técnica K-fold para determinar el número de cortes para el cálculo del error de la red neuronal para el siguiente paso de interpretación de resultados

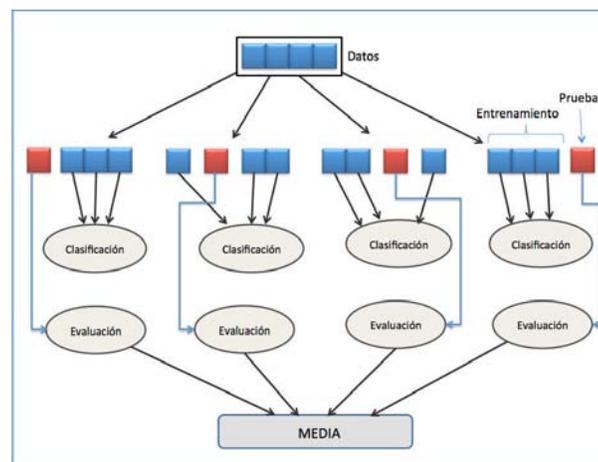


Figura 37. Grafico de la técnica kfold
Fuente: Internet

4.4. Análisis de Consumo de Ancho de Banda

Los datos se extraen por observación de la base de datos del servidor web de la UNAP, para lo cual se utiliza un software de monitoreo de ancho de banda; como se indico en el capitulo anterior; para luego guardarlo en uno de los computadores de evaluación el cual nos garantiza un acceso a los archivos en cualquier momento.

El aplicativo de monitoreo de ancho de banda nos permite analizar el consumo de ancho de banda y ofrecer visibilidad completa independiente mente de los equipos de comunicaciones como routers y switches, a la vez nos proporciona información grafica que permite una mejor visión del consumo a analizar. El software de monitoreo también permite el análisis de información histórica guardada e información completa sobre velocidad, trafico de paquetes etc., también permite la configuración de parámetros de búsqueda por rangos de tiempo.

En las siguientes figuras se puede apreciar el consumo de ancho de banda bajo diferentes parámetro de configuración.

Traffic Statistics

#	Summary	Statistics
1	Total Sessions	621,360
2	Total Bytes Transferred	3.06GB
3	Most Active Date By Sessions	2015-03-02
4	Total Users	537
5	Total Applications	251
6	Total Destinations	4,319
7	Average Sessions Per Day	621,360
8	Average Bytes Per Day	3.06GB

Figura 38. Estadísticas de trafico de un (01) día.
Fuente: Aplicación de monitoreo

Traffic Summary

Bandwidth Summary

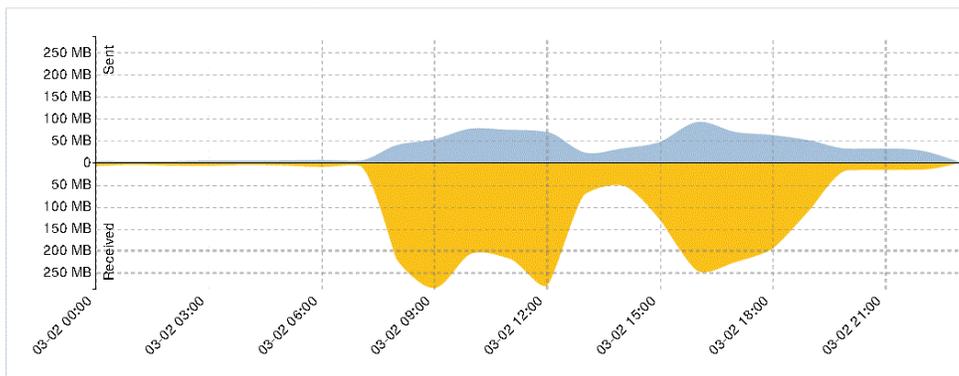


Figura 39. Resumen de trafico de ancho de banda de un (01) día.
Fuente: Aplicación de monitoreo

Bandwidth Summary

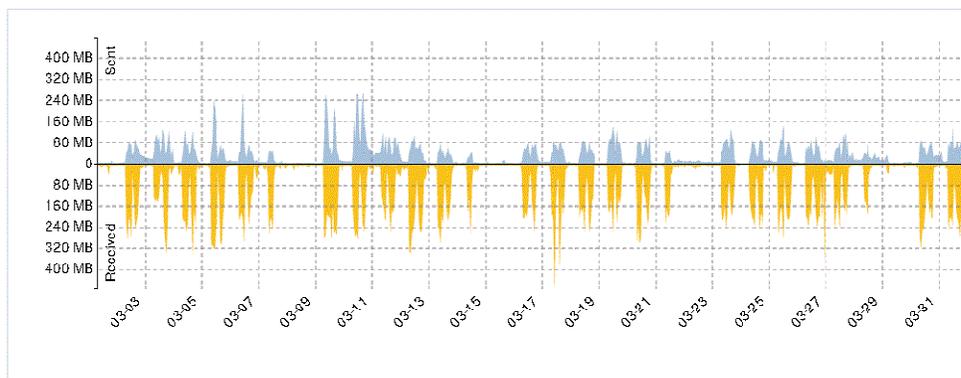


Figura 40. Resumen de ancho de banda de un (01) mes.
Fuente: Aplicación de monitoreo

Del software de monitoreo se obtuvieron los siguientes valores de consumo de ancho de banda:

Tabla 9. Tabla de datos del software de monitoreo

1er MES									
SEMANA1			SEMANA2		SEMANA3		SEMANA4		
DIAS	FECHA	BANDWITCH	FECHA	BANDWITCH	FECHA	BANDWITCH	FECHA	BANDWITCH	
LUN	02/02/2015	2.22 GB	09/02/2015	4.04 GB	16/02/2015	3.66 GB	23/02/2015	2.24 GB	
MAR	03/02/2015	2.93 GB	10/02/2015	3.77 GB	17/02/2015	2.94 GB	24/02/2015	3.68 GB	
MIR	04/02/2015	3.08 GB	11/02/2015	2.36 GB	18/02/2015	2.53 GB	25/02/2015	4.05 GB	
JUE	05/02/2015	2.99 GB	12/02/2015	2.84 GB	19/02/2015	3.33 GB	26/02/2015	2.33 GB	
VIE	06/02/2015	3.95 GB	13/02/2015	3.18 GB	20/02/2015	4.23 GB	27/02/2015	3.57 GB	
2do MES									
SEMANA5			SEMANA6		SEMANA7		SEMANA8		
DIAS	FECHA	BANDWITCH	FECHA	BANDWITCH	FECHA	BANDWITCH	FECHA	BANDWITCH	
LUN	02/03/2015	3.06 GB	09/03/2015	4.15 GB	16/03/2015	2.68 GB	23/03/2015	2.83 GB	
MAR	03/03/2015	3.22 GB	10/03/2015	4.54 GB	17/03/2015	3.26 GB	24/03/2015	2.84 GB	
MIR	04/03/2015	3.43 GB	11/03/2015	3.37 GB	18/03/2015	2.74 GB	25/03/2015	3.18 GB	
JUE	05/03/2015	3.98 GB	12/03/2015	3.75 GB	19/03/2015	2.83 GB	26/03/2015	3.05 GB	
VIE	06/03/2015	3.04 GB	13/03/2015	2.95 GB	20/03/2015	3.03 GB	27/03/2015	2.93 GB	
3er MES									
SEMANA9			SEMANA10		SEMANA11		SEMANA12		SEMANA13
DIAS	FECHA	BANDWITCH	FECHA	BANDWITCH	FECHA	BANDWITCH	FECHA	BANDWITCH	FECHA
LUN	30/03/2015	3.25 GB	06/04/2015	4.34 GB	13/04/2015	3.62 GB	20/04/2015	2.94 GB	27/04/2015
MAR	31/03/2015	3.53 GB	07/04/2015	2.56 GB	14/04/2015	2.55 GB	21/04/2015	2.48 GB	28/04/2015
MIR	01/04/2015	3.07 GB	08/04/2015	2.82 GB	15/04/2015	4.09 GB	22/04/2015	3.37 GB	29/04/2015
JUE	02/04/2015	2.85 GB	09/04/2015	3.04 GB	16/04/2015	3.11 GB	23/04/2015	4.23 GB	30/04/2015
VIE	03/04/2015	2.90 GB	10/04/2015	3.78 GB	17/04/2015	3.44 GB	24/04/2015	3.65 GB	

Fuente: Elaboración propia

4.5. Análisis de Ruido

Por ruido se entiende toda componente de tensión o intensidad indeseada que se superpone con la componente de señal que se procesa o que interfiere con el proceso de medida.

El ruido de un sistema se puede clasificar en uno de los dos siguientes grupos:

- **Ruido interno o inherente:** que corresponden al que se genera en los dispositivos electrónicos como consecuencia de su naturaleza física (ruido térmico, ruido por

cuantización de las cargas, ruido de semiconductor, etc.). El ruido inherente es de naturaleza aleatoria.

- **Ruido externo o interferencias:** que corresponde al que se genera en un punto del sistema como consecuencia de acoplamiento eléctrico o magnético con otro punto del propio sistema, o con otros sistemas naturales (tormentas, etc.) o construidos por el hombre (motores, equipos, etc.). El ruido de interferencia puede ser periódico, intermitente, o aleatorio. Normalmente se reduce, minimizando el acoplo eléctrico o electromagnético, bien a través de blindajes, o bien, con la reorientación adecuada de los diferentes componentes y conexiones.

El ruido se puede abordar desde dos puntos de vista:

- Mediante métodos que tratan de **reducir el ruido en sus fuentes y en su propagación**, como son las técnicas de cableado, blindaje, o diseño de dispositivos de bajo ruido. Estas técnicas son las más óptimas ya que no degradan las prestaciones del sistema, aunque su aplicación no siempre es eficaz o posible.
- Mediante métodos de **filtrado y promediado de la señal**, para amortiguar el nivel de ruido frente a la señal que se procesa. Estas técnicas suelen ser de aplicación más general y efectiva, pero suelen reducir las prestaciones (por ejemplo, anchura de banda) del sistema.

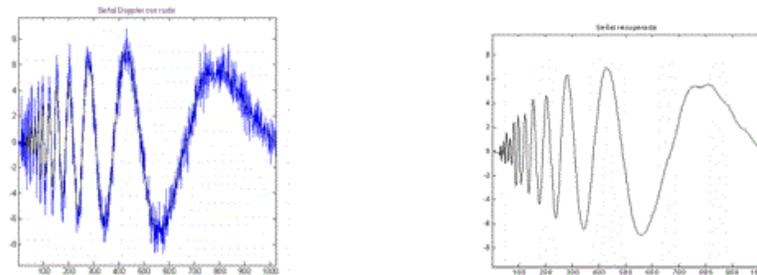


Figura 41. Señal con Ruido.

Fuente: Internet

4.6. Aplicación de Algoritmos de Procedimientos

En esta fase se ejecutan los algoritmos de producción; Retropropagación y Levenberg-Marquardt; para predecir el consumo de ancho de banda a partir de los datos de entrada que se van a ingresar.

4.7. Cálculo de MAPE

Después de realizar el experimento utilizando la red neuronal de Retropropagación y Levenberg-Maguardt, en la fase de prueba se procede con la medición del error de cada uno de ellos, como se indica en la figura siguiente:

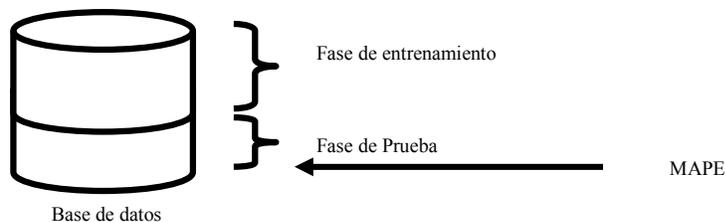


Figura 42. Aplicación de MAPE.

Fuente: Elaboración propia

Se debe definir para un tiempo T un erro promedio PEt:

$$PEt=100*(Pt-Pt')/Pt$$

Donde:

- Pt: Consumo de ancho de banda observado en el tiempo T.
- Pt': Consumo de ancho de banda pronosticad por la red neuronal en el tiempo T.

Se delimitara el valor de N (el número de muestras para la predicción) para calcular la variable dependiente MAPE.

En la figura siguiente podemos apreciar el proceso para calcular el MAPE de un modelo de red neuronal en su fase de prueba donde se observa que para el pronostico se ha considerado n observaciones de consumo de ancho de banda en un día y hora determinada, obteniendo el valor resultante el cual se compara con el vector real observado para así calcular los errores correspondientes y finalmente el MAPE (Porcentaje de Error Absoluto Medio) del modelo teniendo en cuenta el valor de N como número de muestra para el MAPE.

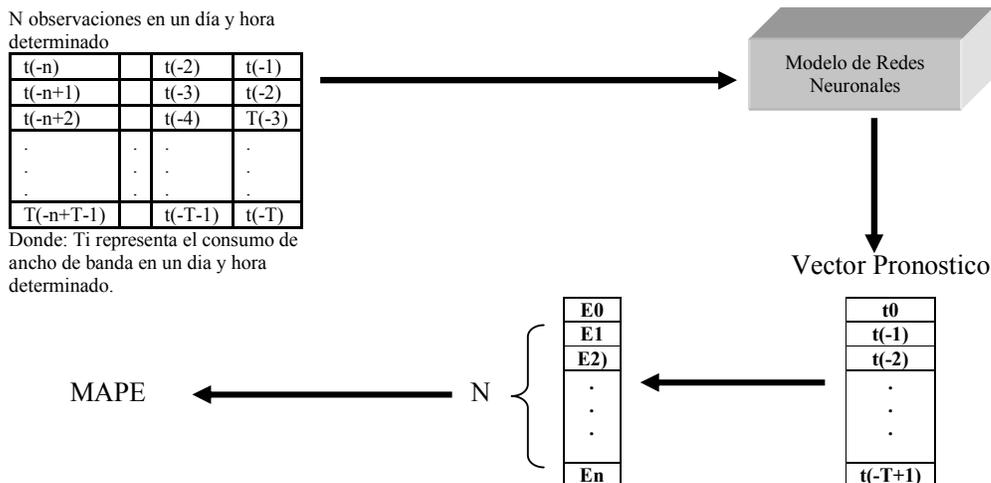


Figura 43. Proceso del Cálculo del MAPE.
Fuente: Elaboración propia

4.8. Identificación del modelo Neuronal de menor MAPE

El MAPE es un número positivo, el que para efectos de decidir cuál de los modelos se ajusta mejor a los datos, se deben comparar sus MAPE's y seleccionar aquel que muestre el MAPE más bajo, generalmente este valor es igual o debajo del novel 0.05.

4.9. Aplicación de Minería de Datos para la Construcción de Modelos de Redes Neuronales

La aplicación del algoritmo de minería de datos requiere la realización de actividades previas de preparación de datos y posteriores de interpretación y evaluación de resultados obtenidos.

La minería de datos se apoyan en las redes neuronales para la predicción del valor de ciertas variables, permite la búsqueda de nueva información de utilidad en grandes volúmenes de datos, en una red neuronal tendríamos múltiples nodos que constituyen

puntos de entrada de los datos. Esos datos son agrupados y sometidos a un tratamiento mediante un algoritmo que da lugar a que se obtengan unos resultados.

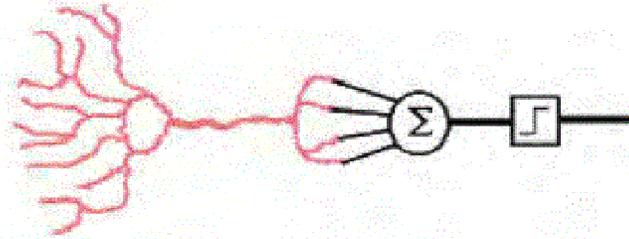


Figura 44. Modelo de Red Neuronal para minería de datos.

Fuente: Internet

Un algoritmo de minería de datos es un conjunto de cálculos y reglas heurísticas que permite crear un modelo de minería de datos a partir de los datos. Para crear un modelo, el algoritmo analiza primero los datos proporcionados, en busca de tipos específicos de patrones o tendencias. El algoritmo usa los resultados de este análisis para definir los parámetros óptimos para la creación del modelo de minería de datos. A continuación, estos parámetros se aplican en todo el conjunto de datos para extraer patrones procesables y estadísticas detalladas.

4.10. Identificación de Valores Óptimos de las Medidas de Desempeño de los Modelos

Las variables que se utilizan son la variable dependiente MAPE y el modelo de red neuronal a utilizar, la cual vamos a obtener mediante el experimento teniendo en cuenta las demás variables independientes.

Tabla 10. Valores Óptimos para Análisis de Resultados

ALGORITMO	VARIABLES	MUESTRA	ERROR MEDIO	ERROR MEDIO REDONDEO

Fuente: Elaboración propia

Variable independiente: Modelo de Red Neuronal Categoría asignada al algoritmo de entrenamiento a usar en el experimento el cual tendrá los valores de algoritmo de Retropropagación y algoritmo de Levenberg-Marquardt

Variable Dependiente: MAPE se calculara según la fórmula descrita.

Capítulo 5

Metodología de la investigación

5.1 Selección de Tema

La internet es hoy por hoy el nuevo paradigma de comunicaciones, es la gran plataforma mundial de acceso a la información, con su aparición se eliminaron las fronteras comerciales, y la distribución y despliegue de aplicaciones tiene un alcance mundial, simplemente con acceder a este servicio.

No se puede obviar el hecho de que se trata de un servicio por lo que debe tener un proveedor, con el cual debemos celebrar un contrato donde se especifiquen las condiciones técnicas y comerciales para el acceso a este servicio.

Dado que se trata de la red de redes donde todos concurrimos por diferentes medios de acceso y por diferentes razones; generamos grandes cantidades de datos, que incluyen llamadas de red por medio del ancho de banda, lo cual hace que el tráfico de red sea un problema.

Los acceso a la red de internet consumen ancho de banda, el mismo que debe ser planificado ya que dispone de una determinada capacidad. Se debe conocer la capacidad que debe tener el ancho de banda para satisfacer la demanda del servicio de internet en un determinado momento.

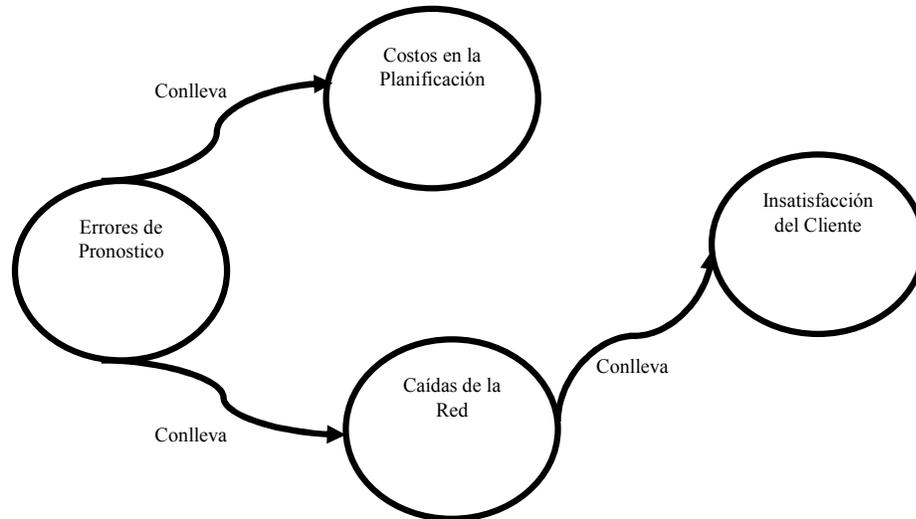
La planificación debe consistir en satisfacer la necesidad de acceso a internet dado un presupuesto anual y una infraestructura de tecnología. Se debe pronosticar el consumo de ancho de banda para conocer la capacidad de una línea o un medio de acceso para transmitir información ya que la saturación del mismo trae consigo cuantiosas pérdidas para las instituciones al no poder utilizar la aplicaciones web.

Actualmente se han desarrollado varios modelos basados en redes neuronales que permiten la predicción del consumo de ancho de banda, como el algoritmo de Retropropagación y Levenberg-Marquardt.

Las instituciones que cuentan con aplicaciones web, reconocen al ancho de banda como un recurso vital para la satisfacción de clientes internos y externos, lo que hace que se deba saber en el momento adecuado la cantidad de ancho de banda a requerir para poder satisfacer el flujo de información en la web sin ocasionar un sobre costo.

5.2 Identificación del problema

Las instituciones deben satisfacer la demanda de flujo de información de los clientes externos e internos lo que obliga la planeación de recursos a un determinado costo.



*Figura 45. Idea del problema.
Fuente: Elaboración propia*

Se debe pronosticar el consumo de ancho de banda, con una mayor precisión en el pronóstico reduce los costos de planificación, por lo que es razonable y necesario un modelo que explique el comportamiento del consumo de ancho de banda.

5.3 Revisión de la Literatura

Se encontró la siguiente literatura:

- **FUNDAMENTOS DE LAS REDES NEURONALES ARTIFICIALES: HARDWARE Y SOFTWARE**

Autores:

BONIFACIO MARTÍN DEL BRÍO

Dpto. Ingeniería Eléctrica y Electrónica

Escuela Universitaria de Ingeniería Técnica Industrial

Universidad de Zaragoza

CARLOS SERRANO CINCA

Dpto. de Contabilidad y Finanzas

Facultad de C. Económicas y Empresariales

Universidad de Zaragoza (1995)

RESUMEN: Las redes neuronales artificiales tratan de modelizar esquemáticamente la estructura hardware del cerebro, para reproducir sus características computacionales. Estos sistemas de procesamiento de información, paralelos, distribuidos y adaptativos, a partir de datos del entorno y empleando algoritmos numéricos, son capaces de aprender de la experiencia.

En este artículo realizamos una introducción a los sistemas neuronales artificiales. En primer lugar, exponemos sus aspectos esenciales, en cuanto a la estructura de la neurona,

arquitectura de la red y aprendizaje. A continuación describimos con brevedad algunos de los modelos más conocidos. Por último, comentamos las diferentes maneras de realizar un sistema neuronal, y sus aplicaciones a la resolución de problemas prácticos.

- **PRONÓSTICO DE CARGA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES**

Autor: JAIRO A. MENDOZA VARGAS

Ingeniero Electricista

Profesor Asistente Universidad Tecnológica de Pereira (2006)

RESUMEN: El presente artículo hace un recuento acerca de la carga eléctrica (energía eléctrica) , su comportamiento y las variables que se involucran en la realización de un sistema que haga el pronóstico de esta. Posteriormente se plantea una técnica de pronóstico basada en redes neuronales artificiales, haciendo una corta descripción y proponiendo un modelo

- **BUENAS PRÁCTICAS PARA LA OPTIMIZACIÓN DE ANCHOS DE BANDA LIMITADOS**

Autor: Alejandra Stolk

Centro de Teleinformación

Corporación Parque Tecnológico de Mérida, Mérida 5101, Venezuela (2009)

RESUMEN: El presente documento tiene como finalidad mostrar en primer lugar el estado actual de la utilización de Internet en instituciones públicas, exponer los antecedentes del Estado en materia de telecomunicación y generación de aplicaciones para la automatización de procesos basados en el uso de Internet.

Este primer grupo de recomendaciones conforma un primer borrador de las medidas que se pueden conformar en un documento de carácter general de buenas prácticas para la optimización del uso y administración de los enlaces de internet para las instituciones públicas en Venezuela.

Este primer acercamiento a Políticas de Buenas Prácticas para optimización de anchos de banda limitados en las instituciones Públicas fue impulsado por el movimiento Internet Prioritaria, con el fin de iniciar procesos de aprendizaje en el uso de Internet, en defensa de su condición estratégica para mejorar la actividad pública; la autora compiló ideas aportadas por distintas personas y ensambló el documento gracias a una investigación previa sobre el tema en otros países, tomando como referencia piloto la Universidad de Los Andes para impulsar las primeras políticas.

- **UN NUEVO ENFOQUE EN EL TRATAMIENTO DE LAS REDES NEURONALES APLICACIÓN Y EXPERIMENTACIÓN EN SISTEMAS**

Autore: MELCHOR ANTONIO MARÍN MUÑOZ

Universidad Nacional de Educación a Distancia (2010)

RESUMEN: Esta tesis doctoral analiza la estructura matemática de una red neuronal artificial, en particular de un perceptrón multicapa. Una vez realizado este análisis se calculan las formas cerradas del Jacobiano y del Hessiano, que se emplean para realizar un estudio sobre las funciones de transferencia no lineal de las neuronas escondidas y para diseñar dos nuevos algoritmos de entrenamiento para el perceptrón multicapa.

El estudio de las funciones de transferencia arroja conclusiones interesantes que en algunos casos se oponen a lo habitualmente aceptado en el área de las redes neuronales artificiales. Por ejemplo, se demuestra que la función logística no reúne las características óptimas para emplearse como función de transferencia, mientras que otras funciones tradicionales como la tangente hiperbólica resultan mucho más eficaces; también se observa que funciones que no se emplean habitualmente en el área de las redes neuronales artificiales, como por ejemplo la función seno, presentan mejores resultados que la función logística.

Al estudiar la forma cerrada de la parte lineal del Jacobiano se presenta la oportunidad de diseñar un nuevo algoritmo de entrenamiento de redes neuronales; las pruebas experimentales confirman que el nuevo algoritmo es claramente superior a la propagación hacia atrás estándar en el conjunto de los problemas utilizados en esta Tesis Doctoral. Basándose en la forma cerrada de la parte no lineal del Jacobiano se desarrolla otro algoritmo de entrenamiento también muy superior a la propagación hacia atrás.

Por último se diseñan un conjunto de circuitos electrónicos en un simulador para la implementación de una red neuronal artificial. El diseño modular de estos circuitos permite la implementación de nuevos algoritmos de entrenamiento con un mínimo trabajo de diseño.

• REDES NEURONALES Y PREDICCIÓN DE TRÁFICO

Autores:

NELSON STIVET TORRES ÁLVAREZ

Ingeniero electrónico

Estudiante de la Maestría en Ciencias de la Información y las Comunicaciones de la Universidad Distrital Francisco José de Caldas. Bogotá, Colombia.

nstorresa@correo.udistrital.edu.co

CÉSAR HERNÁNDEZ

Ingeniero electrónico

Magíster en Ciencias de la Información y las Comunicaciones.

Docente e investigador de la Universidad Distrital Francisco José de Caldas. Bogotá, Colombia.

cahernandezs@udistrital.edu.co

LUIS F. PEDRAZA

Ingeniero electrónico

Magíster en Ciencias de la Información y las Comunicaciones.

Docente e investigador de la Universidad Distrital Francisco José de Caldas. Bogotá, Colombia.

lfpedrazam@udistrital.edu.co

Fecha de Aceptación: 29 Agosto 2011

RESUMEN: El presente documento muestra el desarrollo de un modelo de tráfico basado en redes neuronales. Los datos de tráfico que se utilizaron en el entrenamiento de la red neuronal se extrajeron de una red de datos LAN Ethernet a través del snifer Ethereal; también se utilizó el software MATLAB para modelar la red neuronal de tres capas.

Los resultados obtenidos evidencian la gran flexibilidad y precisión de las redes neuronales en el modelamiento de tráfico de una red Ethernet, si se cuenta con el suficiente número de muestras de tráfico para entrenarla.

- **TÉCNICAS DE OPTIMIZACIÓN DE PARÁMETROS DE RED PARA LA MEJORA DE LA COMUNICACIÓN EN SERVICIOS DE TIEMPO REAL**

Autor: JOSÉ M. SALDAÑA MEDINA

Doctorado en Tecnologías de la Información y Comunicaciones en Redes Móviles (2011)

RESUMEN: En esta tesis se presenta un conjunto de estudios sobre técnicas de optimización del tráfico de servicios de tiempo real, aplicables en el caso de que un número de flujos compartan la misma ruta.

En estos escenarios la eficiencia se puede mejorar mediante la compresión de cabeceras cuyos campos se repiten o se incrementan de uno en uno para todos los paquetes del flujo. Posteriormente se pueden multiplexar varios paquetes en uno más grande, que se envía extremo a extremo utilizando un túnel. Algunos de estos métodos de optimización, como ocurre para servicios basados en RTP, han sido estandarizados por el IETF. También pueden adaptarse a otros servicios con características similares.

Se han realizado pruebas encaminadas a medir la mejora que se puede obtener mediante estos métodos en servicios de tiempo real. Se han realizado medidas tanto en entornos reales como en otros emulados mediante virtualización o simulados. Se han evaluado los parámetros de calidad objetiva resultantes, como el retardo o las pérdidas, que posteriormente se han traducido en valores de calidad percibida, utilizando estimadores del MOS (Mean Opinion Score, puntuación de la opinión media).

El primer servicio estudiado ha sido el de Voz sobre IP (Voice over IP, VoIP). Para ello, se ha diseñado un sistema de telefonía IP similar a los utilizados en entornos empresariales, incluyendo un sistema que multiplexa las llamadas simultáneas entre el mismo par de sucursales. El sistema se ha implementado en un entorno de pruebas, utilizando herramientas de software libre. Se han realizado también medidas de la mejora que se puede obtener en los parámetros de calidad de servicio cuando se multiplexa un número de flujos nativos. Por último, se han realizado simulaciones para evaluar el efecto en la probabilidad de admisión.

El segundo servicio de tiempo real que se ha probado ha sido el del género FPS (First Person Shooter, Tirador en Primera Persona) de juegos online. Se ha adaptado el estándar de multiplexión para el tráfico de estos juegos, debido a que, a diferencia del servicio de voz, no usan el protocolo RTP sino que envían paquetes UDP. Se han estudiado, analíticamente y mediante simulaciones, las mejoras que se pueden obtener, mostrando que se consiguen ahorros significativos en ancho de banda y paquetes por segundo, que se pueden traducir en mejoras en los parámetros de calidad.

5.4 Definición del Tipo de Investigación

Se trata de una investigación de tipo cuantitativa, descriptiva y correlacional porque se busca predecir cómo se puede comportar la variable dependiente (MAPE) conociendo el comportamiento de las variables independientes relacionadas (algoritmos de entrenamiento, números de neuronas, números de iteraciones, número de observaciones y porcentaje de muestra), aplicando técnicas de redes neuronales al consumo de ancho de banda.

5.5 Establecer Hipótesis

- **Hipótesis:** El modelo de red neuronal con algoritmo de aprendizaje Levenberg-Marquardt es el instrumento apropiado para el pronóstico de ancho de banda de internet por tener un menor porcentaje de error (MAPE) que el modelo de red Neuronal con algoritmo de aprendizaje de Retropropagación.
- **Hipótesis Alterna** El modelo de red neuronal con algoritmo de aprendizaje Levenberg-Marquardt es el instrumento apropiado para el pronóstico de ancho de banda de internet por tener un igual porcentaje de error (MAPE) que el modelo de red Neuronal con algoritmo de aprendizaje de Retropropagación.
- **Hipótesis Nula:** El modelo de red neuronal con algoritmo de aprendizaje Levenberg-Marquardt no es el instrumento apropiado para el pronóstico de ancho de banda de internet por tener un mayor porcentaje de error (MAPE) que el modelo de red Neuronal con algoritmo de aprendizaje de Retropropagación.

5.6 Diseño de Investigación

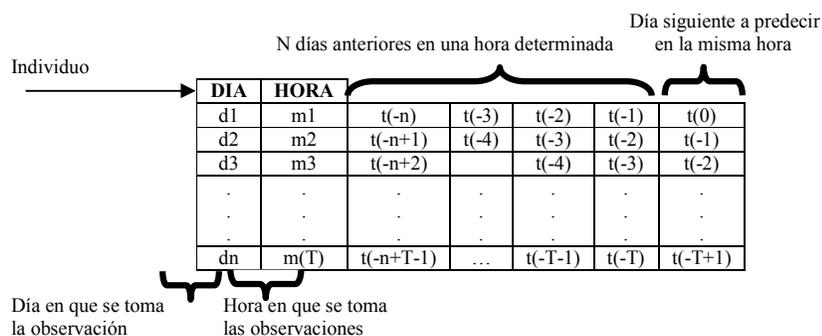
Se trata de un tipo de diseño experimental, por que las variables independientes son deliberadamente manipuladas para generar observaciones en los experimentos que nos permitan saber el comportamiento de la variable dependiente (MAPE).

Objetos de la Investigación

Los objetos de la investigación están agrupados por sus características:

- Consumo de ancho de banda del día siguiente en una hora determinada (consumo deseado t_0)
- Consumo de ancho de banda del i -ésimo día anterior en u a hora determinada ($t(-i)$).
- Un día de la semana($d(i)$).

T: Tamaño de la muestra



5.7 Población y Muestra

Para la población y muestra tenemos lo siguiente:

Población

La población está compuesta por un conjunto de $(364/N)$ objetos de estudio donde 364 son observaciones que corresponden a la medición del consumo de ancho de banda de la UNAP durante los meses de febrero marzo y abril del 2015.

Muestra

La técnica de muestreo es no probabilística por conveniencia ya que los elementos no dependen de la probabilidad sino de causas relacionadas con las características del investigador, la ventaja es que podemos tener una cuidadosa y controlada elección de sujetos con las características especificadas deseadas.

Considerando lo anterior, tendremos una muestra sesentaicuatro (64) objetos de estudio.

VARIABLE INDEPENDIENTE	DEFINICIÓN CONCEPTUAL	DIMENSIÓN	INDICADORES	ÍNDICES
"Modelo de Red Neuronal"	Las RN se utilizan para aprender patrones y relaciones de datos.	Modelos	Algoritmo de Entrenamiento: 1.- Retropropagación 2.- Levenberg-Marquardt	Alto Desempeño Bajo Desempeño
		Componentes de los Modelos	Número de Neuronas de la Capa Intermedia (Ci)	Altas Unidades Mediana Unidades Bajas Unidades
		Aprendizaje	Numero de Iteraciones(I)	Altas Unidades Mediana Unidades Bajas Unidades
		Predicción	Número de Observaciones para la Predicción(N)	Altas Unidades Mediana Unidades Bajas Unidades
		Entrenamiento	Porcentaje de la muestra de Entrenamiento(h)	Altas Unidades Mediana Unidades Bajas Unidades
Variable Dependiente	Definición Conceptual	Dimensión	Indicadores	Índices
Consumo de Ancho de banda	Es la capacidad de una línea determinada para transmitir información	Modelo	Porcentaje de Error Absoluto (MAPE)	Alto Bajo

Tabla 11. Matriz De Operacionalización

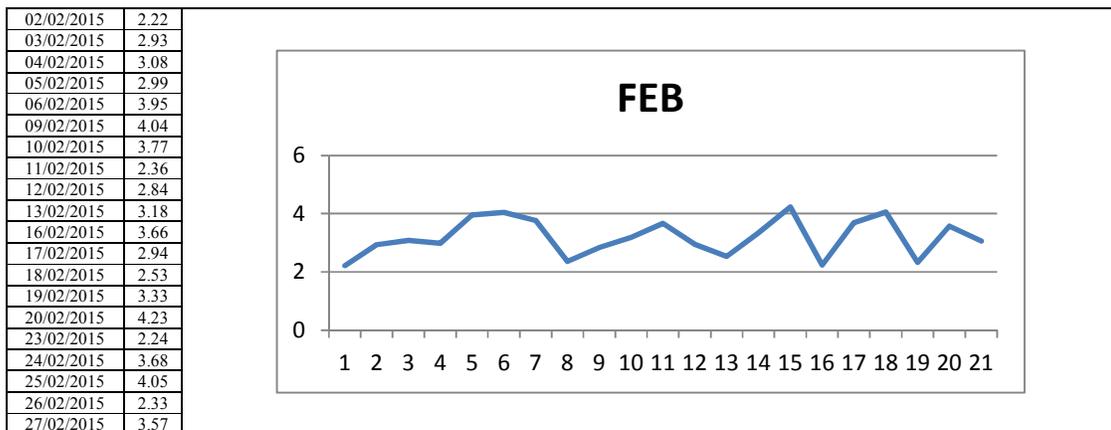
Fuente: Elaboración propia

5.8 Recolección de Datos

Debido a las limitaciones de tiempo y disponibilidad los datos a tomar del software de monitoreo serán una vez al finalizar el día.

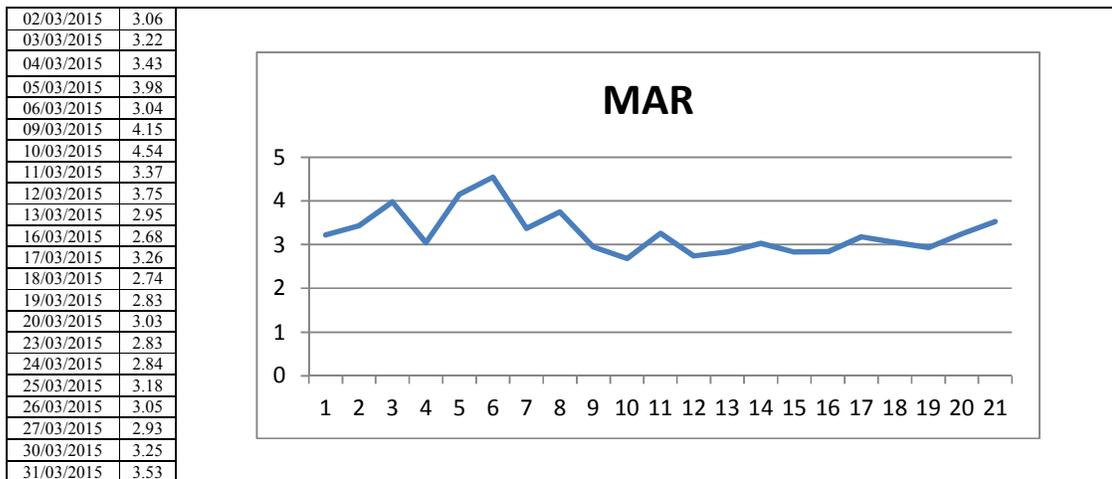
El comportamiento de la data recolectada es el siguiente:

Tabla 12. Bandwitch Febrero 2015



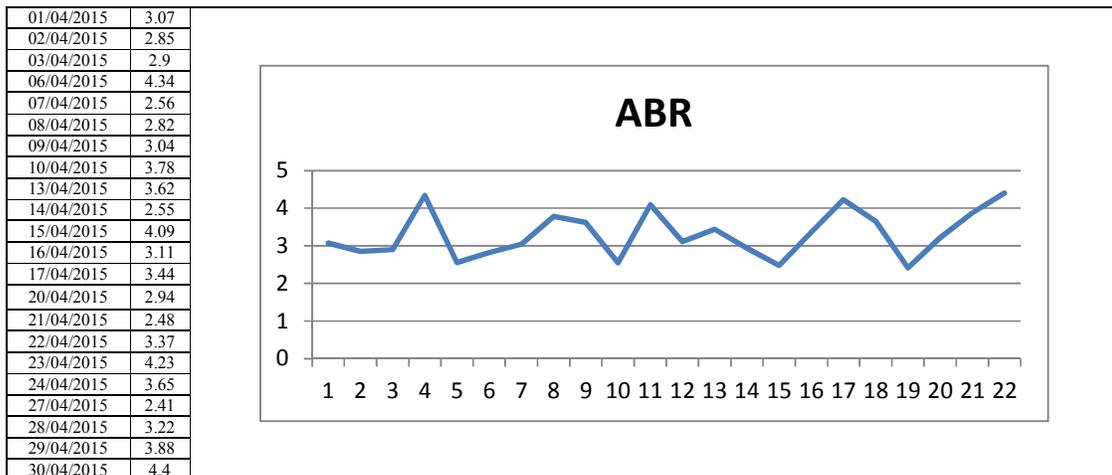
Fuente: Elaboración propia

Tabla 13. Bandwitch Marzo 2015



Fuente: Elaboración propia

Tabla 14. Bandwitch Abril 2015



Fuente: Elaboración propia

De la data se puede verificar que las curvas de consumo de ancho de banda no son uniformes, por lo que se debe encontrar el error respecto al valor optimo deseado según el modelo del algoritmo empleado.

5.9 Análisis de Datos

Se procederá con análisis exploratorios con series de tiempo, mientras que la última será de ajuste vale decir de entradas y salidas y ajustes de curvas. (input-output and curve fitting). Esto debido a que tenemos una serie de tiempo por lo que se trata de una estimación inter temporal, no obstante, la bondad de ajuste pura que permite replicar comportamientos puede ser tan o más precisa.

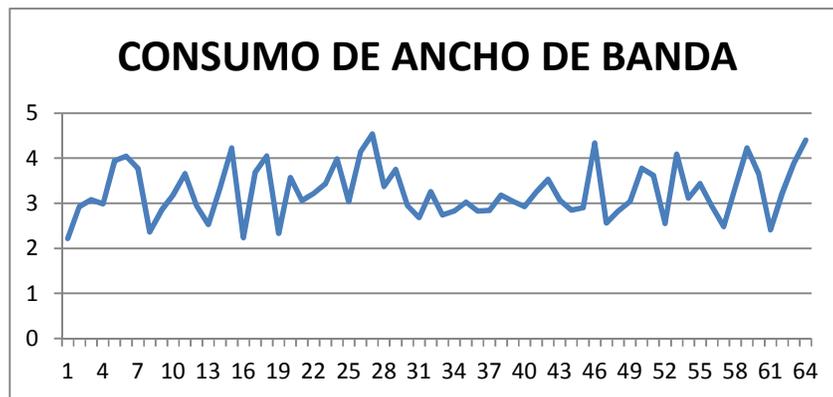
Como se verá más adelante, en el presente caso, el ajustes de curvas o “curve fitting” es sumamente predictor, y será la metodología utilizada, para la predicción dentro del MATLAB.

Así mismo, una vez determinada la mejor alternativa con el algoritmo de Levenberg-Marquardt, se probará el mismo diseño con el algoritmo de Retropropagación (regularización bayesiana ó gradiente conjugado escalado).

A continuación los datos del consumo de ancho de banda:

Tabla 15. Bandwitch Total

FECHA	GB
02/02/2015	2.22
03/02/2015	2.93
04/02/2015	3.08
05/02/2015	2.99
06/02/2015	3.95
09/02/2015	4.04
10/02/2015	3.77
11/02/2015	2.36
12/02/2015	2.84
13/02/2015	3.18
16/02/2015	3.66
17/02/2015	2.94
18/02/2015	2.53
19/02/2015	3.33
20/02/2015	4.23
23/02/2015	2.24
24/02/2015	3.68
25/02/2015	4.05
26/02/2015	2.33
27/02/2015	3.57
02/03/2015	3.06
03/03/2015	3.22
04/03/2015	3.43
05/03/2015	3.98
06/03/2015	3.04
09/03/2015	4.15
10/03/2015	4.54
11/03/2015	3.37
12/03/2015	3.75
13/03/2015	2.95
16/03/2015	2.68
17/03/2015	3.26
18/03/2015	2.74
19/03/2015	2.83
20/03/2015	3.03
23/03/2015	2.83
24/03/2015	2.84
25/03/2015	3.18
26/03/2015	3.05
27/03/2015	2.93
30/03/2015	3.25
31/03/2015	3.53
01/04/2015	3.07
02/04/2015	2.85
03/04/2015	2.9
06/04/2015	4.34
07/04/2015	2.56
08/04/2015	2.82
09/04/2015	3.04
10/04/2015	3.78
13/04/2015	3.62
14/04/2015	2.55
15/04/2015	4.09
16/04/2015	3.11
17/04/2015	3.44
20/04/2015	2.94
21/04/2015	2.48
22/04/2015	3.37
23/04/2015	4.23
24/04/2015	3.65
27/04/2015	2.41
28/04/2015	3.22
29/04/2015	3.88
30/04/2015	4.4



Fuente: Elaboración propia

5.10 Presentación de resultados

Se logro implementar la RNA gracias a la aplicación de MATLAB (Toolbox), para evaluar el comportamiento del sistema.

1er Análisis Exploratorio - Aprendizaje:

- Se utilizó la aplicación de redes neuronales para series de tiempo, dentro del toolbox “Neural Networks” de Matlab R2015a.
- Se definió como un problema “No lineal Autoregresivo” (NAR), el cual permite predecir una serie de datos, basada en número determinado (“d”) de datos anteriores ($Y[t-d]$)
- La serie objetivo o serie deseada además será el mismo consumo de ancho de banda (CAB), en la forma de una matriz de columnas (vector fila).
- El modelo, desde un punto de vista global tendría la siguiente forma, siendo el recuadro azul la red neuronal que será diseñada en las especificaciones siguientes:

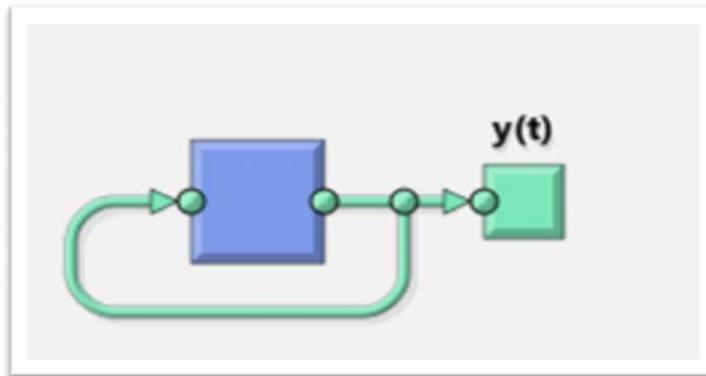


Figura 46. Diseño de Red Neuronal Global.

Fuente: Aplicación de análisis

- Se utilizaron las siguientes proporciones para la validación de los datos.
 - Datos sujetos a entrenamiento: 42 (70%)
 - Datos sujetos a validación: 9 (15%)
 - Datos de prueba: 9 (15%)
- Diseño de la Red Neuronal.
 - Número de neuronas ocultas: 10
 - Numero de rezagos: 2

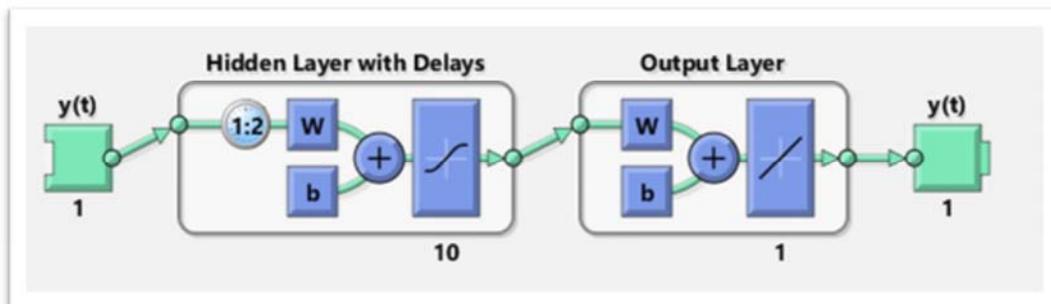


Figura 47. Diseño de Red Neuronal Detallada.

Fuente: Aplicación de análisis

- Entrenamiento de la Red Neuronal
 - Algoritmo de Levenberg-Marquardt
 - PRIMERA VEZ (12 iteraciones)

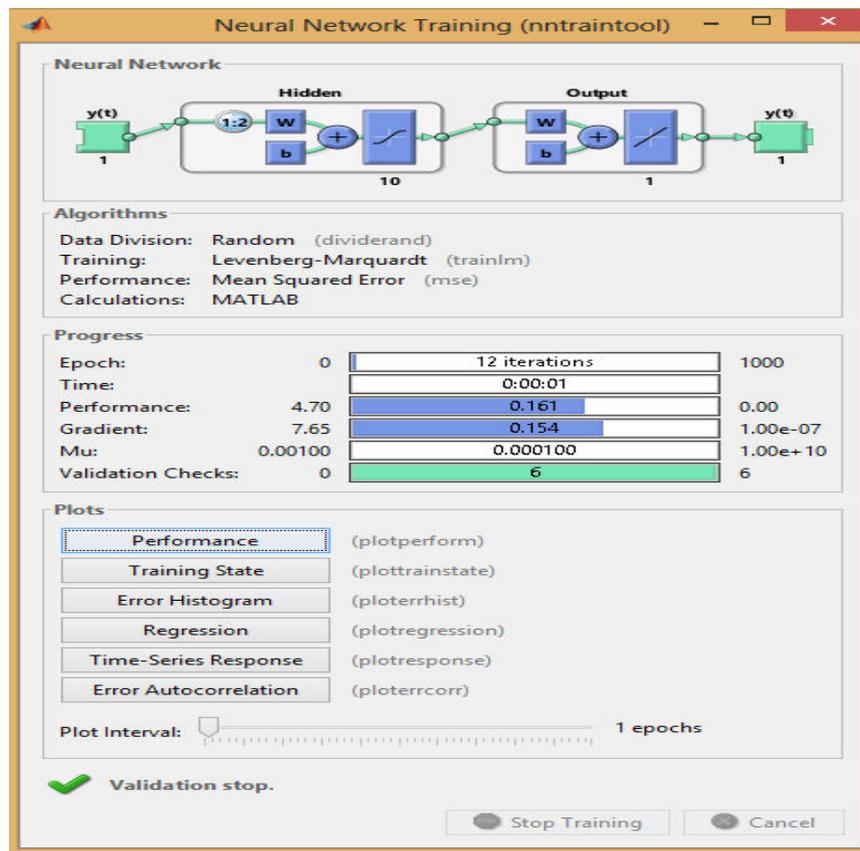


Figura 48. Entrenamiento 12 Iteraciones.
Fuente: Aplicación de análisis

- Se presenta además la evolución del error medio.

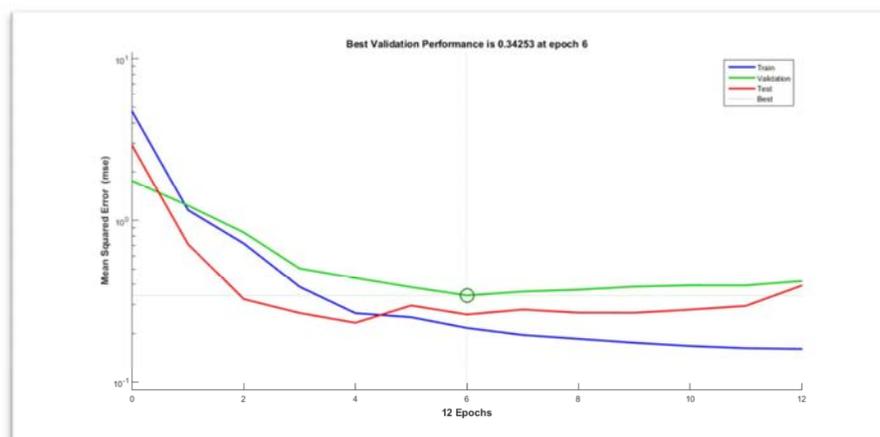


Figura 49. Evolución del Error Medio de 12 Iteraciones.
Fuente: Aplicación de análisis

- Así mismo, se presentan las regresiones de la data de entrenamiento ($R^2 = 53\%$), de validación (16%) y de prueba (30%).

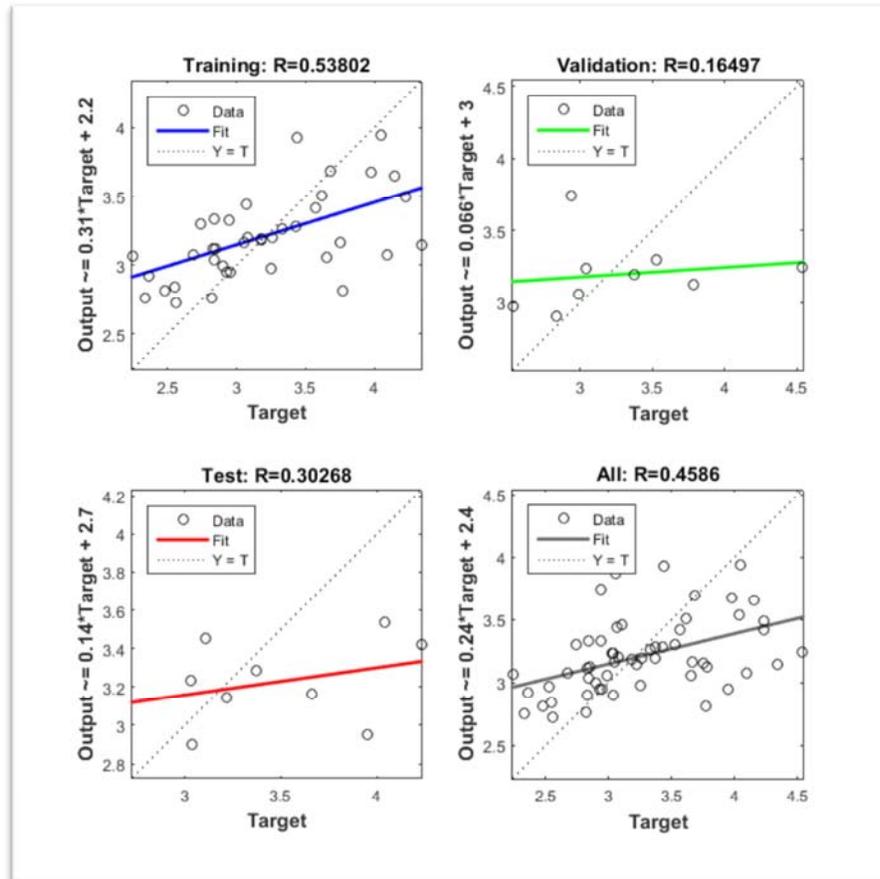


Figura 50. Regresión de la Data de 12 Iteraciones.
Fuente: Aplicación de análisis

- SEGUNDA VEZ (8 iteraciones).

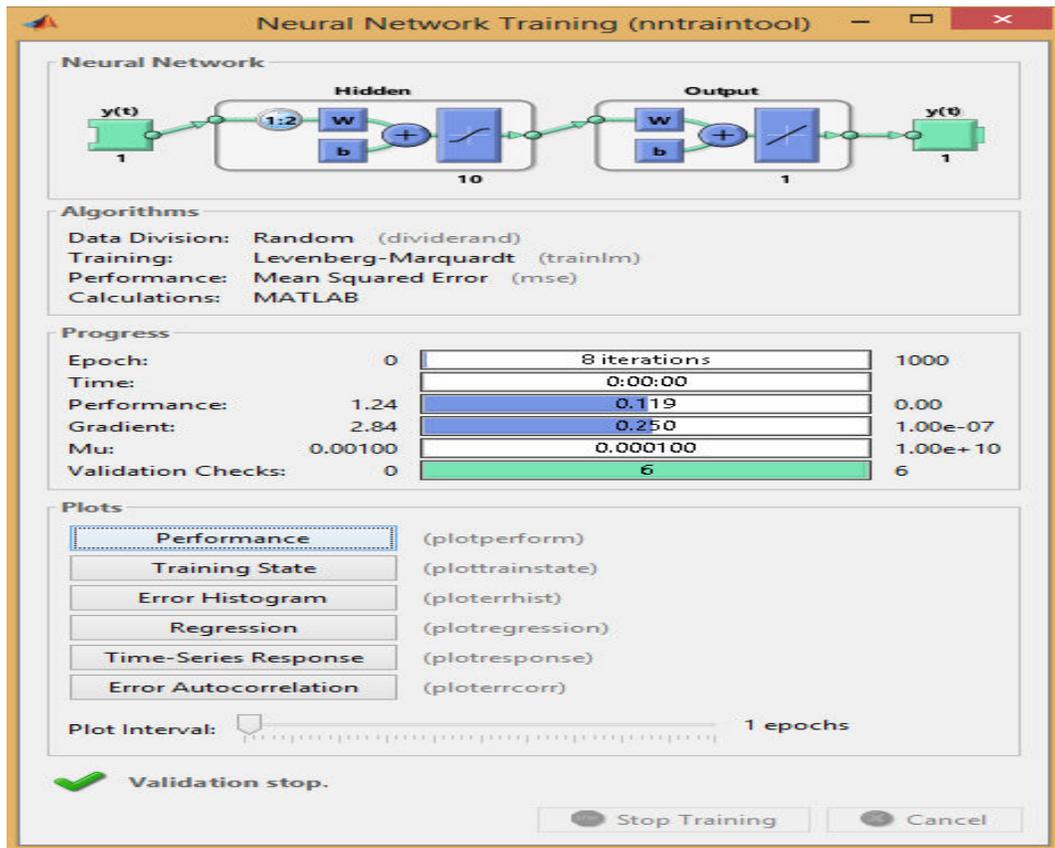


Figura 51. Entrenamiento 8 Iteraciones.
Fuente: Aplicación de análisis

- Y el error medio es ligeramente menor.

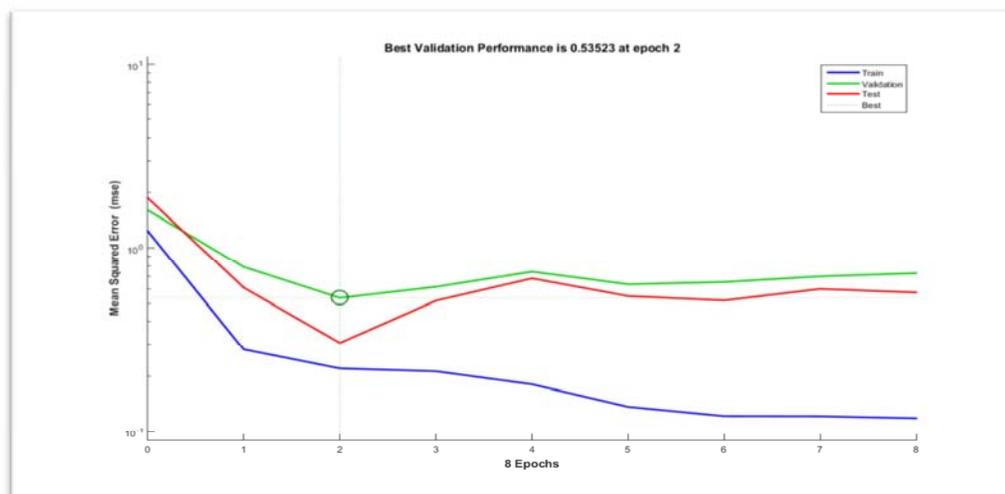


Figura 52. Evolución del Error Medio de 8 Iteraciones.
Fuente: Aplicación de análisis

- Puede apreciarse que mejoraron las iteraciones y mejoró el R2 para los datos de prueba, aunque empeoraron para el resultado global.

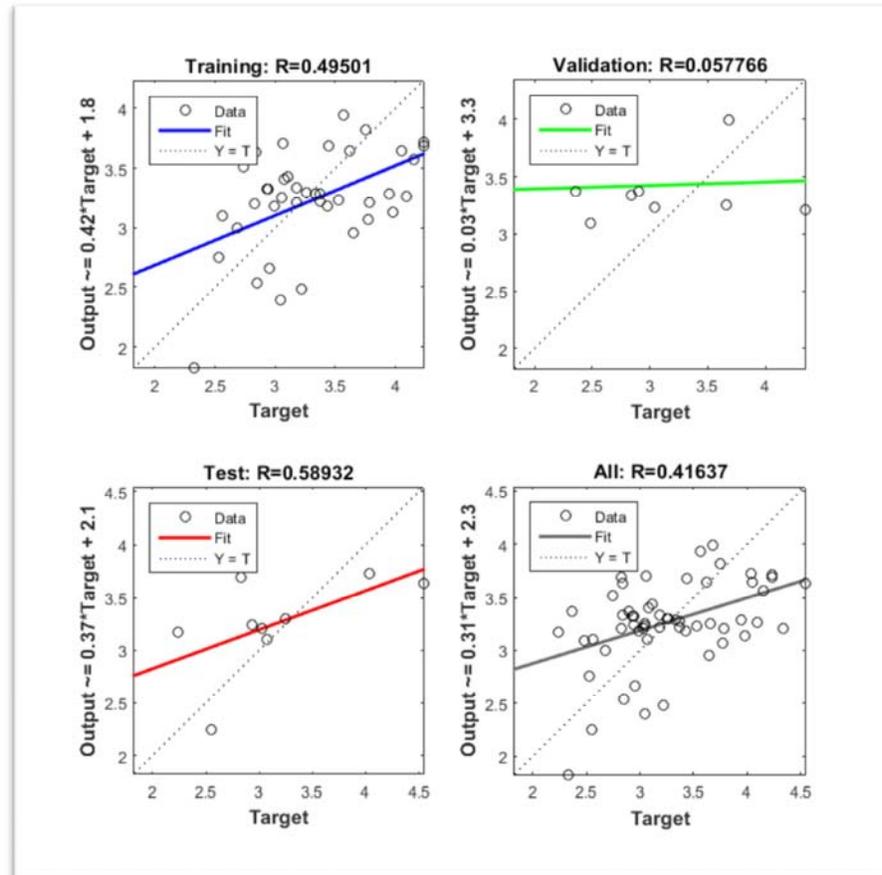


Figura 53. Regresión de la Data de 8 Iteraciones.
Fuente: Aplicación de análisis

- TERCERA VEZ (7 ITERACIONES)

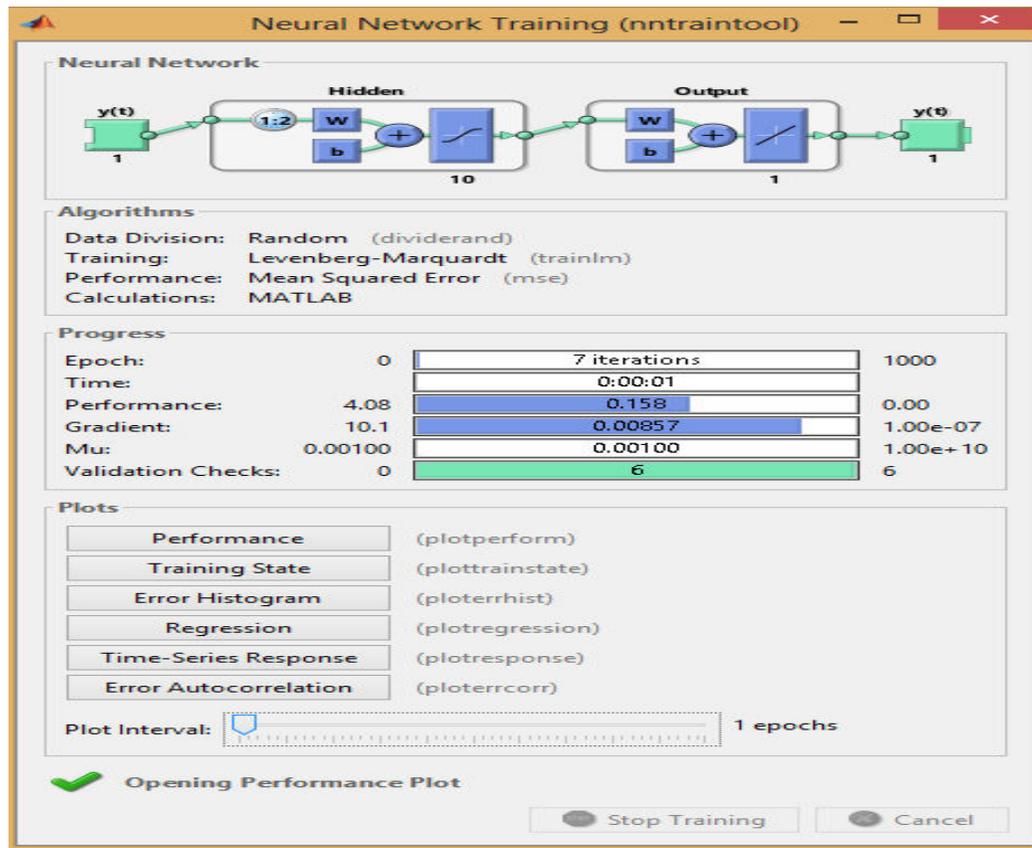


Figura 54. Entrenamiento 7 Iteraciones.
Fuente: Aplicación de análisis

- El error medio es menor

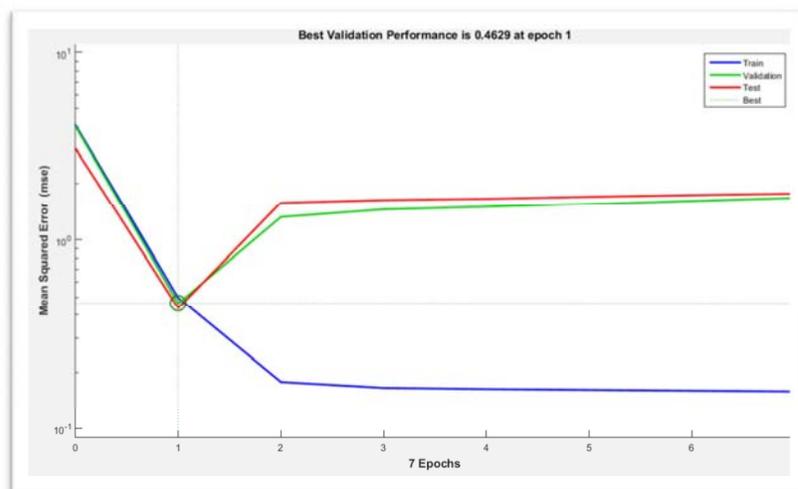
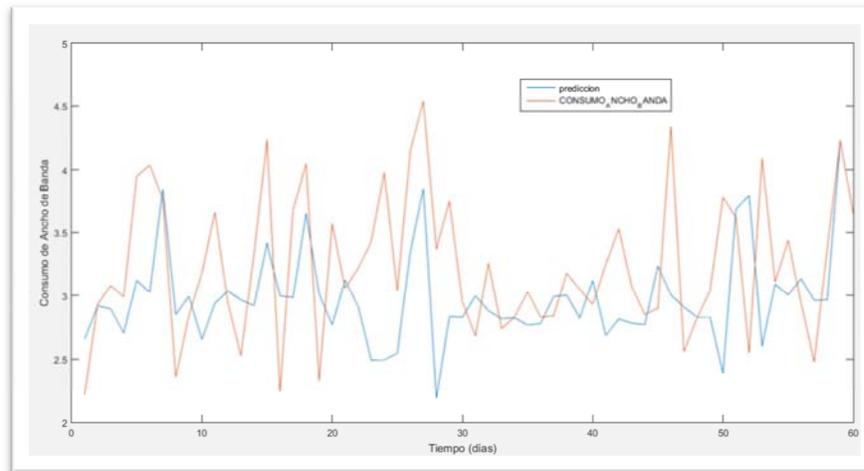


Figura 55. Evolución del Error Medio de 7 Iteraciones.
Fuente: Aplicación de análisis

- Considerando ello, se procedió a estimar los valores predichos en este estado de la red, con el siguiente resultado comparativo.

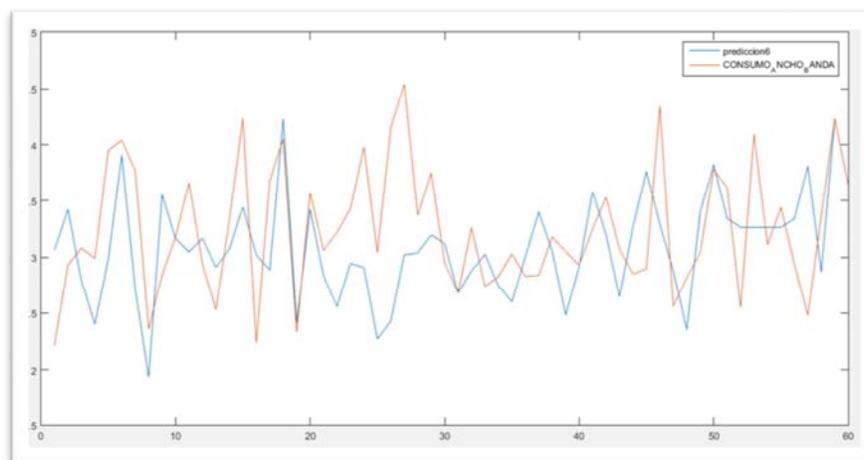


*Figura 56. Predicción del Consumo de Ancho de Banda de 7 Iteraciones.
Fuente: Aplicación de análisis*

- Se procedió a registrar el script (CODIGO_SCRIPT_1)

Revisión Del Análisis Exploratorio Con Consideración De Autocorrelación

- Se procedió a repetir el experimento considerando el número de rezagos recomendados por la red (9)
- Se obtuvo un R2 mayor de 50%.
- Se impuso como target la misma serie y se obtuvo un R2 de 62%.
- Se procedió a predecir.
- Se graficó la comparación



*Figura 57. Predicción del Consumo de Ancho de Banda de 9 Rezagos.
Fuente: Aplicación de análisis*

2do Análisis Exploratorio

- Se reformulo el modelo anterior, tomándose como rezagos 5 días. Todo lo demás por defecto y/o igual.
- Se reformuló el modelo anterior, tomándose como rezagos 20. Todo lo demás por defecto y/o igual.
- Se grafican solo los errores.

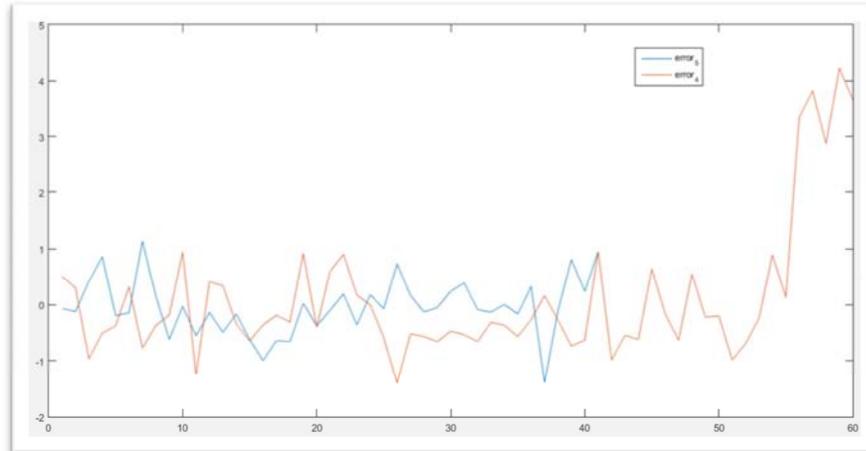


Figura 58. Error de Predicción con Rezagos de 5 y 20 días.

Fuente: Aplicación de análisis

- Considerando que una mayor historia podría ser buena para la red, se estimará la predicción, ya no con el algoritmo de Levenberg-Marquardt, sino Retropropagación :
 - Con regularización bayesiana, hasta que la prueba tenga un R superior al 50%. Después de varios intentos la red no lograba aprender.
 - Con el algoritmo del gradiente conjugado escalado. Después de varios intentos la red no lograba aprender.
- Nuevamente se retrocedió en lo previsto, y se aplicó con 5 rezagos.
 - Regularización bayesiana → Red no logró aprender.
 - Gradiente conjugado escalado → Red no logró aprender.

3er Análisis Exploratorio – Ajuste de curvas

- En consecuencia se procedió a repetir el experimento considerando
 - Datos de aprendizaje. 27 (45%)
 - Datos de validación. 12 (15%)
 - Datos de prueba. 21 (40%)
- Se obtuvo un R2 mayor de 97%.
- Se impuso como target la misma serie y se obtuvo un R2 de 98%.
- Se impuso como inputs y targets a la serie original.
- Se procedió a predecir.
- Se graficó el diseño y el entrenamiento. Los resultados son muy satisfactorios.

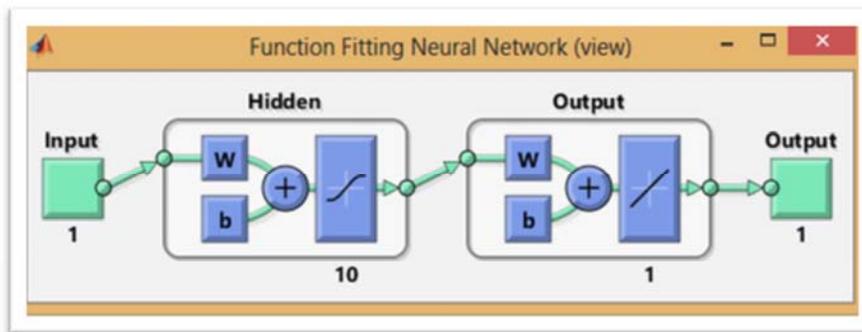


Figura 59. Diseño de Red Neuronal.
Fuente: Aplicación de análisis

Train Network
Train the network to fit the inputs and targets.

Train Network

Choose a training algorithm:

Levenberg-Marquardt

This algorithm typically takes more memory but less time. Training automatically stops when generalization stops improving, as indicated by an increase in the mean square error of the validation samples.

Train using Levenberg-Marquardt. (trainlm)

Retrain

Results

	Samples	MSE	R
Training:	27	9.68427e-5	9.99741e-1
Validation:	12	3.23575e-2	9.83767e-1
Testing:	21	3.78923e-2	9.70512e-1

Plot Fit Plot Error Histogram Plot Regression

Notes

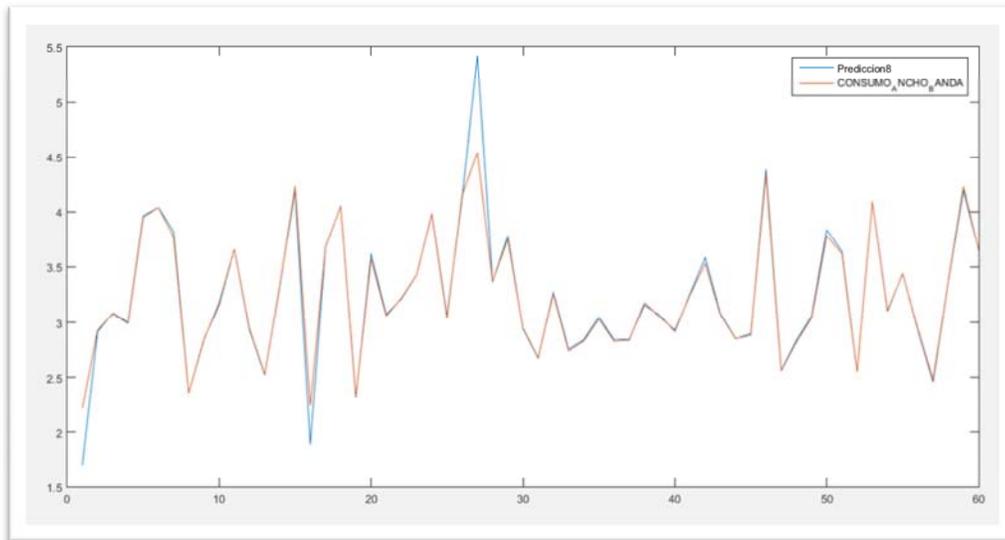
- Training multiple times will generate different results due to different initial conditions and sampling.
- Mean Squared Error is the average squared difference between outputs and targets. Lower values are better. Zero means no error.
- Regression R Values measure the correlation between outputs and targets. An R value of 1 means a close relationship, 0 a random relationship.

Open a plot, retrain, or click [Next] to continue.

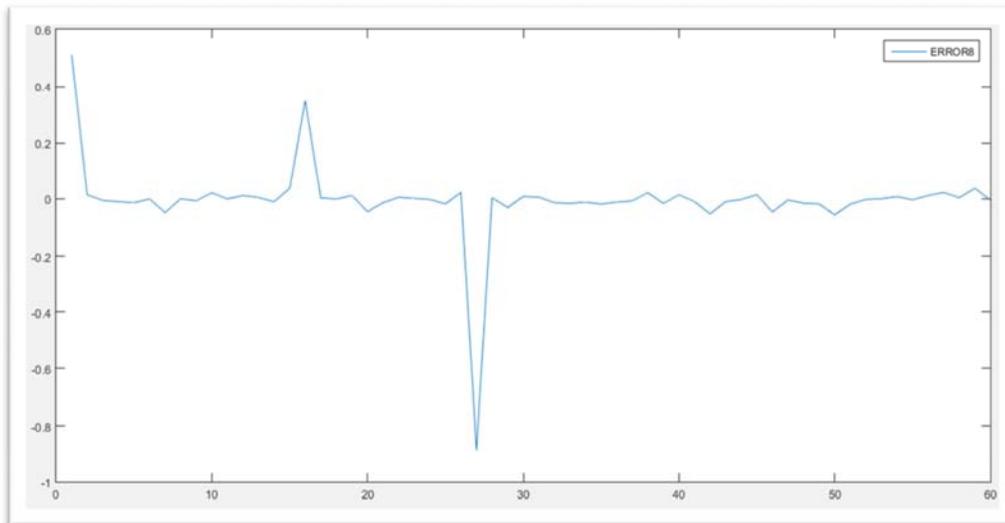
Neural Network Start Welcome Back Next Cancel

Figura 60. Interface de Entrenamiento – Levenberg-Marquardt.
Fuente: Aplicación de análisis

- Predicción con algoritmo de Levenger-Marquardt don el el error medio se aproxima a cero.



*Figura 61. Predicción de Consumo de Ancho de Banda con Ajuste de Curva.
Fuente: Aplicación de análisis*



*Figura 62. Error Medio de Predicción con Ajuste de Curva.
Fuente: Aplicación de análisis*

4to Análisis Exploratorio.-Comparación con Métodos de Retropropagación.

- Mismo diseño, pero con algoritmo de Retropropagación de regularización bayesiana

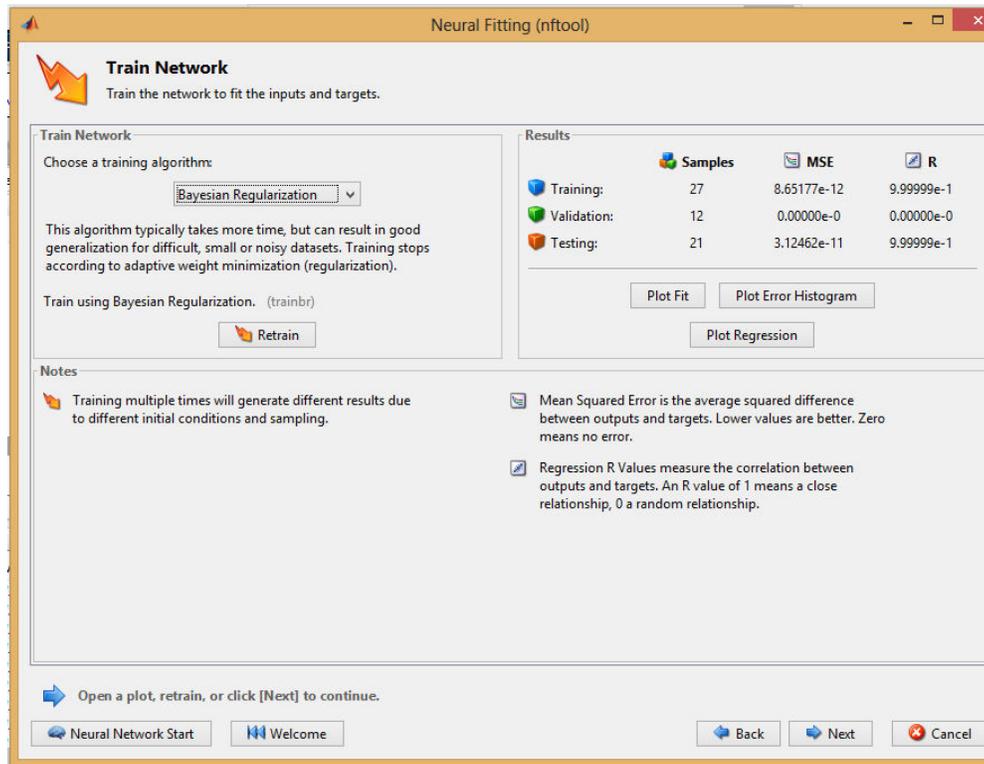


Figura 63. Interface de Entrenamiento – Retropropagación.
Fuente: Aplicación de análisis

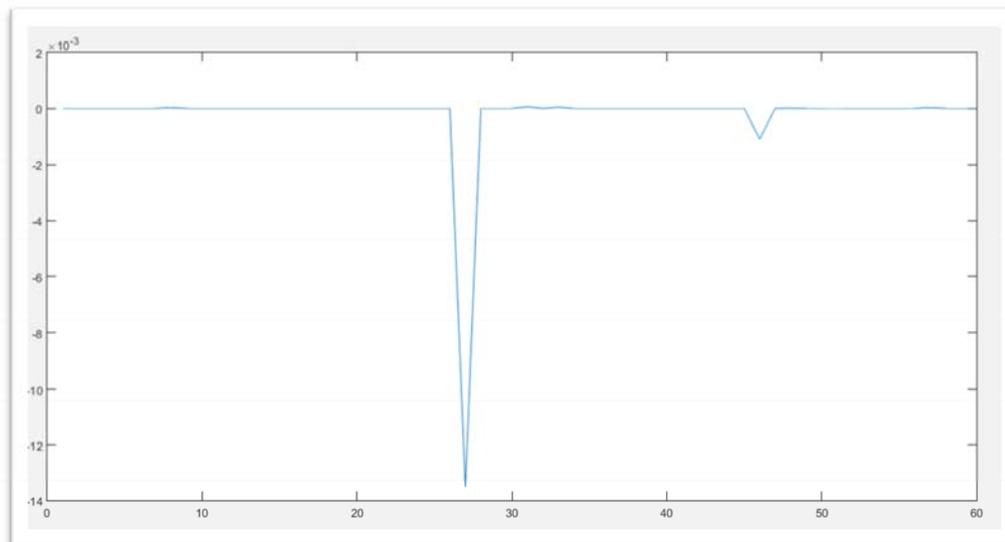


Figura 64. Error Medio de Predicción con Ajuste de Curva.
Fuente: Aplicación de análisis

- Mismo diseño, pero con algoritmo de Retropropagación de gradiente conjugado escalado.

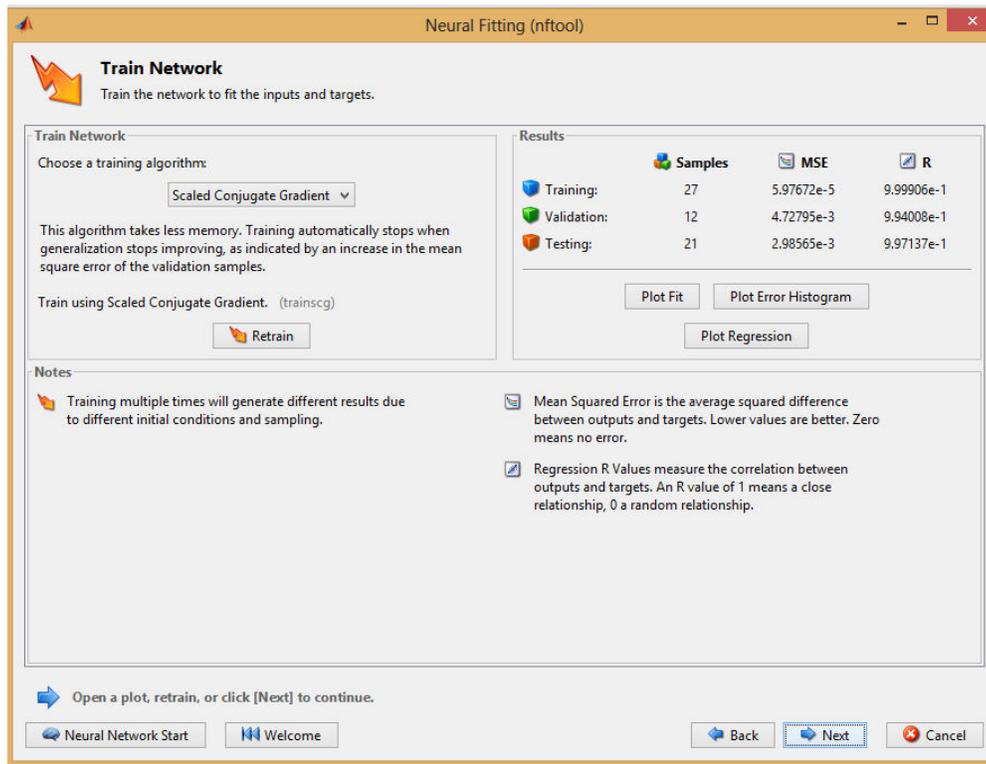


Figura 65. Interface de Entrenamiento – Retropropagación2.
Fuente: Aplicación de análisis

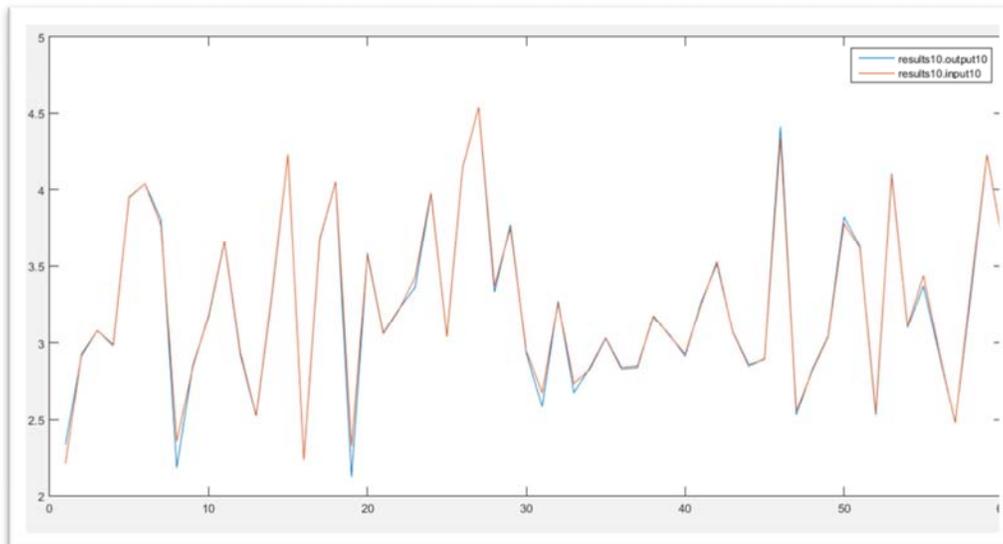


Figura 66 Predicción de Consumo de Ancho de Banda con Ajuste de Curva.
Fuente: Aplicación de análisis

Capítulo 6

Análisis de resultados

6.1. Comparación de Resultado

Realizando la comparación de los modelos de redes neuronales y el modelo real, respecto a la predicción, se obtiene lo siguiente:

Tabla 16. Comparacion de resultados.

ALGORITMO	VARIABLES	MUESTRA	ERROR MEDIO	ERROR MEDIO REDONDEO
Levenberg-Marquardt	Training	27	0.0000968427	9.68×10^{-5}
	Validation	12	0.0323575	3.24×10^{-2}
	Testing	21	0.00378923	3.79×10^{-2}
Retropropagación - Bayesian Regularization	Training	27	0.0000000000865177	8.65×10^{-12}
	Validation	12	0.0	0.00
	Testing	21	0.000000000312462	3.12×10^{-11}
Retropropagación – Scaled Conjugate Gradient	Training	27	0.0000597672	5.98×10^{-5}
	Validation	12	0.00472795	4.73×10^{-3}
	Testing	21	0.00298565	2.99×10^{-3}

Fuente: Elaboración propia

Según los datos presentado el error medio más bajo lo tiene el algoritmo de Retropropagación.

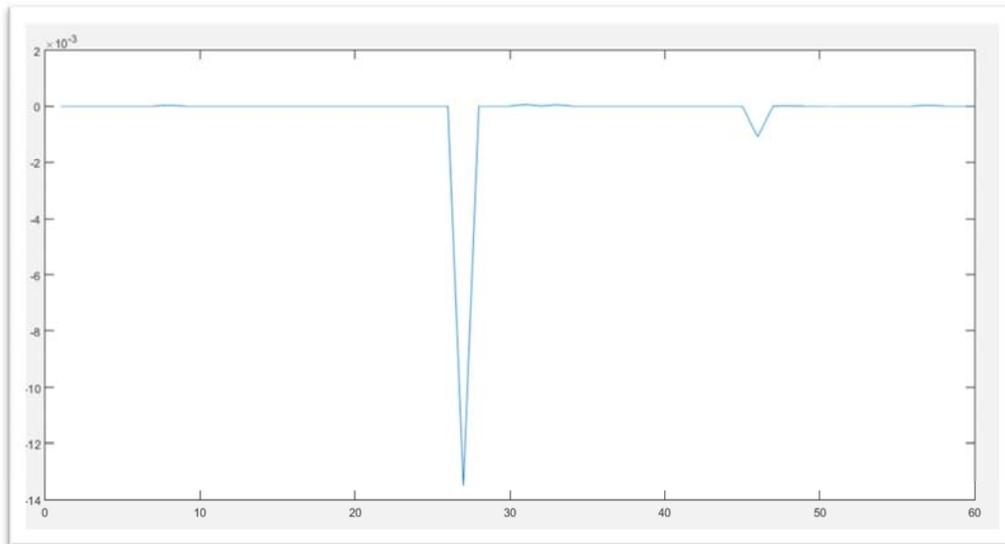


Figura 67. Error Medio de Predicción con Retropropagación Bayesian Regularization .

Fuente: Aplicación de análisis

De todo lo anterior, también se desprende que el Algoritmo Levenberg-Marquardt facilita el aprendizaje de la red a diferencia de las demás opciones de algoritmos que presenta el MATLAB.

No obstante, es necesario realizar la misma comparación utilizando el criterio del Porcentaje de Error Absoluto (MAPE) a fin de elaborar una comparación más final; no obstante el poder explicativo de la correlación parece ser suficiente.

6.2. Pronostico Optimizado de frecuencia en el consumo de ancho de banda en el espectro radioeléctrico de la Universidad Nacional de la Amazonia Peruana.

Según la información resultante el pronóstico optimizado de frecuencia en el consumo de ancho de banda, se lograría mediante la aplicación de redes neuronales con el algoritmo de Retropropagación para la predicción de consumo de ancho de banda.

Esto permitiría conocer cuál es la necesidad proyectada de la red con respecto al acceso a internet, para un determinado horizonte de tiempo.

Conclusiones y recomendaciones

7.1. Conclusiones

Se puede optimizar el consumo de ancho de banda de internet utilizando redes neuronales artificiales, en la medida que podamos predecir el consumo de ancho de banda para un determinado periodo, esto permitiría obtener mejores contratos por este servicio y optimizar también los costes por el mismo.

Sin embargo el presente trabajo es muy revelador ya que se propuso comparara dos algoritmos de redes neuronales el de Retropropagación y el de Levenberg-Maguardt encontrando que según las pruebas realizadas con el MATLAB con data del consumo de ancho de banda de tres meses de la Universidad Nacional de la Amazonia Peruana, el algoritmos de Levenberg-Marquardt es mucho más conveniente para el entrenamiento y aprendizaje de las redes neuronales y el de Retropropagación es mucho más eficiente para la predicción.

Las redes neuronales artificiales en su emulación a la red neuronal biológica, poseen la capacidad de entrenarse y aprender; mientras más variables tengan, mayor deberá ser el numero de datos y las iteraciones que se deben efectuar para su entrenamiento y aprendizaje, siempre salvaguardando el equilibrio ya que se corre el riesgo de que por un lado la red no aprenda por tener pocas iteraciones o por otro lado memorice un evento y lo repita por tener demasiadas iteraciones enseñando lo mismo.

De los resultados del capítulo anterior se desprende que la hipótesis no es aceptada ya que el modelo de red neuronal con algoritmo de aprendizaje Levenberg-Marquardt no es el instrumento apropiado para el pronóstico de ancho de banda de internet por tener un mayor porcentaje de error (MAPE) que el modelo de red neuronal con algoritmo de aprendizaje de Retropropagación.

El concepto de redes neuronales artificiales precede a la década de los años 50 y su campo de acción es muy prometedor, sin embargo, si consideramos lo indicado en la ley de Gordon Moore¹⁹ donde se deja entrever que el conocimiento mundial en tecnologías de información se duplicaría cada 18 meses, nos damos cuenta que ya deberíamos tener grandes avances en lo que respecta a este tema, sin embargo la realidad es otra.

Con el presente trabajo se reconoce el potencial de las redes neuronales, con una actividad tan sencilla como es la predicción del consumo de internet para un tiempo determinado, pero también deja al descubierto la falta de aplicación práctica de esta herramienta.

¹⁹ http://es.wikipedia.org/wiki/Ley_de_Moore

7.2. Recomendaciones

Debido a los resultados obtenidos, convendría ampliar la evaluación de otros algoritmos de redes neuronales y determinar su comportamiento frente al MAPE y también sería recomendable evaluar si las redes neuronales tienen diferente comportamiento tanto para el aprendizaje como para la predicción.

Sería razonable realizar otros tipos de predicciones dada la facilidad con las que las redes neuronales logran aprender distintas realidades que deben ser optimizadas.

Se debería, mejorar los mecanismos para determinar el número de datos de muestra necesarios para el aprendizaje de la neurona artificial.

En el campo de las tecnologías de información y comunicaciones, se debería trabajar en el desarrollo de aplicaciones (software especializado) que emulen de manera específica el comportamiento de las redes neuronales, al respecto no contamos con muchas aplicaciones que abarquen estos campo de acción, y sería una excelente oportunidad para continuar con el presente trabajo, me refiero a desarrollar un software de predicción de consumos de servicios similares al planteado.

Bibliografía

1. ANDREW S. TANENBAUM: “Redes de Computadoras”.
4ta. Edición, Prentice Hall México
México, 2003 - ISBN: 9789702601623
2. BONIFACIO MARTIN DEL RIO: “Redes Neuronales y sistemas Borrosos”.
3ra. Edición, RA-MA
España, 2006 - ISBN: 9788478977437
3. QUINTIN MARTIN, YANIRA PAZ: “Aplicación de las Redes Neuronales a la Regresión”.
1ra. Edición, La Muralla
España, 2007 - ISBN: 9788471337672
4. RAFAEL FLORES, JOSE FERNANDEZ: “Las Redes Neuronales Artificiales Fundamentos Teóricos y Aplicaciones Prácticas”.
1ra. Edición, Gesbiblo
España, 2008 – ISBN: 9788497452465
5. ALBERTO GARCIA: “Inteligencia Artificial”.
1ra. Edición, RC Libros
España, 2012 - ISBN: 9788493945022
6. Redes neuronales.
<http://ingenieria.udea.edu.co/investigacion/mecatronica/mectronics/redes.htm>.
Acceso en Noviembre 2014
7. Redes Neuronales y Predicción del Tráfico.
<http://Dialnet.unirioja.es/3802210>.
Acceso en Enero 2015
8. Pronóstico de Carga a Corto Plazo Utilizando Redes Neuronales Artificiales.
<http://Dialnet.unirioja.es/4819241>.
Acceso en Enero 2015
9. Red Neuronal.
http://es.wikipedia.org/wiki/red_neuronal.
Acceso en Febrero 2015.

10. Redes Neuronales.
<http://www.usmp.edu.pe/publicaciones/boletin/fia/info32/pag4.htm>.
Acceso en Febrero 2015.
11. Redes neuronales.
<http://neo.lcc.uma.es/staff/francis/pdf/pfc-chicano03.pdf>.
Acceso en Marzo 2015.
12. Error porcentual absoluto.
<http://www.assis.com.co/blog-2/error-porcentual-absoluto-medio-mape/>.
Acceso en Marzo 2015.
13. Administración del espectro radioeléctrico.
http://tesis.pucp.edu.pe/repositorio/bitstream/handle/123456789/938/carrillo_palomino_sara_administracion_espectro_radioelectrico.pdf?sequence=1.
Acceso en Marzo 2015.