

UNIVERSIDAD NACIONAL DEL CALLAO

ESCUELA DE POSGRADO

UNIDAD DE POSGRADO DE LA

FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA



**“REDES NEURONALES ARTIFICIALES APLICADAS A
LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS
REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA”**

**TESIS PARA OPTAR EL GRADO ACADÉMICO DE MAESTRO
EN CIENCIAS DE LA ELECTRÓNICA, CON MENCIÓN EN
CONTROL Y AUTOMATIZACIÓN**

AUTORES: APESTEGUIA INFANTES, JUAN ANTONIO

HUARCAYA GONZALES, EDWIN

A handwritten signature in black ink, appearing to read "Juan Antonio Apesteguias Infantes".

Callao, 28 de junio del 2018

PERÚ

A handwritten signature in black ink, appearing to read "Edwin Huarcaya Gonzales".

HOJA DE REFERENCIA DEL JURADO

MIEMBROS DEL JURADO

MSc. RICARDO RAÚL RODRIGUEZ BUSTINZA	:	PRESIDENTE
Dr. NICANOR RAÚL BENITES SARAVIA	:	SECRETARIO
Mg. CÉSAR AUGUSTO SANTOS MEJÍA	:	MIEMBRO
Mg. WILBERT CHÁVEZ IRAZÁBAL	:	MIEMBRO
Dr. SANTIAGO LÍNDER RUBIÑOS JIMÉNEZ	:	ASESOR

N° DE LIBRO : 01

ACTA FOLIO N° : 073

FECHA DE APROBACIÓN : junio 28, 2018

RESOLUCIÓN DIRECTORAL : 041-2018-DUPGFIEE

DEDICATORIA

Agradecimiento especial a Dios y a nuestros padres por su apoyo incondicional sin los cuales esto no se hubiera podido realizar.

Queremos agradecer también a todas las personas que ayudaron y colaboraron en la elaboración de esta Tesis: Amigos, Compañeros de Trabajo y Docentes de la Universidad del Callao.

REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA

ÍNDICE

CARÁTULA	i
PÁGINA DE RESPETO	ii
HOJA DE REFERENCIA DEL JURADO Y APROBACIÓN	iii
DEDICATORIA	iv
ÍNDICE	1
TABLAS DE CONTENIDO	6
INTRODUCCION	8
RESUMEN	9
RESUMO	10

CAPÍTULO - 1

1. PLANTEAMIENTO DE LA INVESTIGACIÓN	11
1.1 Determinación del problema	11
1.2 Formulación del problema	13
1.2.1 Problema general	13
1.2.2 Problemas específicos	13
1.3 Objetivos de la investigación	14
1.3.1 Objetivo general	14
1.3.2 Objetivos específicos	14
1.4 Justificación	14

CAPÍTULO - 2

2. MARCO TEÓRICO	15
2.1 Antecedentes del Estudio	
2.2 Marco Conceptual	16
2.2.1 Fundamentación Ontológica	16
2.2.2 Fundamentación Metodológica	16
2.2.3 Fundamentación Epistemológica	17
2.2.4 Cuidado ambiental y política ambientalista	18
2.2.5 Medio Ambiente – Recursos Hídricos	19
2.2.6 ¿Qué es el “desarrollo sostenible”?	20
2.2.7 Desarrollo sostenible y agua	21
2.2.8 Recursos Hídricos	22

2.2.9	Políticas de Manejo del Agua Potable	24
2.2.10	Sedapal	25
	a. Objetivos de Sedapal	26
	b. Servicios de Saneamiento	26
	c. Servicio de Detección de Fugas (ECRF)	27
2.2.11	Equipos utilizados por el (ECRF)	28
	a. Manómetro	30
	b. Geófono	33
2.2.12	Geófonos Mecánicos	33
2.2.13	Geófonos Electrónicos	34
	a. Geófono Lmic	34
	b. Geófono Xmic	34
2.2.14	Correlador	37
	a. Correlador Electrónico Palmer Micro Call+	38
	b. Correlador Electrónico Aquascan 610	39
	c. Correlador Multipunto Soundsens	40
2.2.15	Redes Neuronales Artificiales	43
	a. Panorama Histórico	44
	b. El modelo biológico	46
	c. Estructura de la neurona	47
	d. Naturaleza bioeléctrica de las neuronas	48
	e. Definición y características de las redes neuronales artificiales	51
	f. La Neurona o Unidad de Proceso	54
	g. El estado de activación	55
	h. Función de salida o transferencia	56
	i. Neuronas con función escalón	56
	j. Neuronas con función lineal y mixta	57
	k. Neuronas con función continua (sigmoideal)	58
2.2.16	Conexiones entre neuronas o pesos	59
2.2.17	Tipos de arquitectura en las redes neuronales artificiales	60
	a. Perceptrón Multicapa (PMC)	61
	b. Red recurrente de Elman	62
	c. Red auto-organizativa de Kohonen	63
	d. Mecanismo de aprendizaje	66
	e. Aprendizaje de las redes PMC	69
	f. Aprendizaje de las redes Elman	71
	g. Aprendizaje de las redes Kohonen	71
2.2.18	El Espectrograma aplicado a la Acústica	73
2.3	Definición de Términos	77

CAPÍTULO - 3

3	VARIABLES E HIPÓTESIS	77
3.1	Definición de variables	77
3.1.1	Algoritmo con Redes Neuronales Artificiales	77
3.1.2	Detección de fugas utilizando redes neuronales artificiales	78
3.1.3	Determinar los factores que afectan la detección de fugas	78
3.2	Operacionalización de variables	78
3.2.1	Variable independiente "X" = Algoritmo con Redes Neuronales Artificiales con Matlab para la detección de fugas no visibles	78
3.2.2	Variable dependiente "Y" = La detección de fugas utilizando redes neuronales artificiales repercutirá en un mejor rendimiento del servicio reduciendo los porcentajes de agua no facturada.	78
3.2.3	Variable Interviniente "Z" = La contaminación sonora (ruido y el tipo de suelo donde se encuentra la tubería influyen en la detección de fugas.	78
3.3	Hipótesis general e hipótesis específicas	78
3.3.1	Hipótesis general	79
3.3.2	Hipótesis específica 1	79
3.3.3	Hipótesis específica 2	79

CAPÍTULO - 4

4	METODOLOGÍA	79
4.1	Tipo de investigación	79
4.2	Diseño de la investigación	80
4.2.1	Modelamiento inteligente utilizando Redes Neuronales	80
4.2.2	Redes Neuronales	81
4.2.3	Origen de los datos	82
4.2.4	Pre Procesamiento	83
4.2.5	Grabación digital de los sonidos	83
4.2.6	Aplicación de filtros y normalización de la señal	86
4.2.7	Codificación y procesamiento de imágenes en Matlab	86
4.2.8	Red Neuronal PCM con Imágenes	87
4.2.9	Instaurar el equipo localizador inteligente	96
4.2.10	Cuantificar el ahorro porcentual	97
4.3	Población y muestra	98

4.3.1	Unidad de análisis	99
4.3.2	Población (N)	99
4.3.3	Tamaño de la Muestra (n_0)	99
4.3.4	Prueba piloto	99
4.4	Procesamiento estadístico y análisis de datos	101
4.4.1	Modelamiento inteligente utilizando Redes Neuronales	101
4.4.2	Instaurar el equipo localizador inteligente	101
4.4.3	Factores que afectan la detección de fugas	101
4.4.4	Procesamiento estadístico y análisis de datos	101

CAPÍTULO - 5

5	RESULTADOS	102
5.1	Modelamiento inteligente utilizando Redes Neuronales	102
5.2	Instaurar el equipo localizador inteligente	102
5.3	Factores que afectan la detección de fugas	102

CAPÍTULO - 6

6	DISCUSIÓN DE RESULTADOS	102
6.1	Contrastación de hipótesis con los resultados	103
6.1.1	Algoritmo con Redes Neuronales Artificiales en MATLAB	103
6.1.2	Detección de fugas utilizando Redes Neuronales	103
6.1.3	Contaminación sonora y tipo de suelo	103
6.2	Contrastación de resultados con otros estudios similares	103

CAPÍTULO - 7

7	CONCLUSIONES	104
7.1.	Modelamiento inteligente utilizando Redes Neuronales	104
7.2	Instaurar el equipo localizador inteligente	104
7.3	Determinar los factores que afectan la detección	104

CAPÍTULO - 8

8	RECOMENDACIONES	104
8.1.	Modelamiento inteligente utilizando Redes Neuronales	105
8.2	Instaurar el equipo localizador inteligente	105
8.3	Determinar los factores que afectan la detección de fugas	105

CAPÍTULO - 9

9	REFERENCIAS BIBLIOGRÁFICAS	105
	ANEXOS	107
	• Matriz de Consistencia	109
	• Esquematización de Elementos para la Tesis de Posgrado en la UNAC	110
	• Algoritmo	111
	• Espectrograma	112
	• Matrices	113

ÍNDICE DE: TABLAS, CUADROS, DIAGRAMAS Y FIGURAS

• TABLAS

Tabla Nº 1 Unidad de medidas de un Manómetro	14
Tabla Nº 2 Tiempos de entrenamiento y porcentaje de éxito de la red PMC	73
Tabla Nº 3 Tiempos de entrenamiento y porcentaje de éxito de la red PMC	98
Tabla Nº 4 Tiempos de entrenamiento y porcentaje de éxito de la red PMC	98

• CUADROS

Cuadro Nº 1 Países con más emisiones de CO ₂	95
Cuadro Nº 2 Correlador Soundsens Especificaciones	112

• FIGURAS

Figura Nº 1 Unidad Móvil de Detección de Fugas	28
Figura Nº 2 Instalación de Tubería Matriz	29
Figura Nº 3 Manómetro de Glicerina para Fluidos presurizados	30
Figura Nº 4 Manómetro de Glicerina especificaciones técnicas	32
Figura Nº 5 Geófono de piso mecánico, muy similar a un estetoscopio	33
Figura Nº 6 Geófono electrónico LMIC	34
Figura Nº 7 Geófono electrónico XMIC	35
Figura Nº 8 Correcto uso de los Geófonos electrónicos XMIC y Lmic	36
Figura Nº 9 Funcionamiento Correlador Palmer	37
Figura Nº 10 Correlador Palmer +	38
Figura Nº 11 Correlador Palmer + en funcionamiento	39
Figura Nº 12 Correlador AquaScan en funcionamiento	40
Figura Nº 13 Correlador Soundsens	41
Figura Nº 14 Software Correlador Soundsens	43
Figura Nº 15 Neurona Biológica	47
Figura Nº 16 Esquema de conexión típica (sinapsis) entre 2 neuronas	48
Figura Nº 17 Propagación del impulso eléctrico a lo largo del axón.	50
Figura Nº 18 Modelo de una neurona artificial	54
Figura Nº 19 Función de transferencia tipo escalón	57
Figura Nº 20 Función de transferencia tipo mixto	58
Figura Nº 21 Función de activación de tipo sigmoideal	59
Figura Nº 22 Arquitectura típica de una red PMC	62
Figura Nº 23 Arquitectura de una red recurrente de Elman	63
Figura Nº 24 Arquitectura de una red auto organizativa de Kohonen	64
Figura Nº 25 Arquitectura de una red auto organizativa de Kohonen MAK	65

Figura N° 26	Descripción Grafica y Matemática de una señal Acústica	75
Figura N° 27	Espectrograma de una muestra de audio	76
Figura N° 28	Diagrama resumen de los pasos metodológicos	81
Figura N° 29	Maqueta a tamaño real de una conexión domiciliaria	82
Figura N° 30	Software Audacity	84
Figura N° 31	Los tres tipos de fugas en una conexión domiciliaria de agua	85
Figura N° 32	Filtro y normalización de la señal	87
Figura N° 33	Conversión y normalización de archivos en Audacity	88
Figura N° 34	Generación del espectrograma en Matlab	89
Figura N° 35	Simplificación del espectrograma tras el procesamiento	90
Figura N° 36	Red PMC utilizada estructura 120-50-5 con tansig y purelin	91
Figura N° 37	Red PMC utilizada estructura 120-50-5	92
Figura N° 38	Red PMC utilizada estructura 120-75-5	93
Figura N° 39	Software de Gestion de Incidencias operativas y comerciales SGIO	95
Figura N° 40	Contrastación de Detección de Fugas en el sistema Periodo Dic 2017	96
Figura N° 41	Detalle de la información con respecto a una Fuga	97
Figura N° 42	Detalle Reporte Fugas 2017	98

INTRODUCCIÓN

El presente plan de tesis de postgrado titulado "REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA" se presenta como un tema de investigación interdisciplinario inédito el cual propone como premisa el modelamiento usando redes neuronales para la detección de fugas de agua potable en las redes de la ciudad de Lima, esto permitirá hacer una detección y clasificación de las fugas en tiempo real y con un margen de error menor con respecto al error humano.

Para identificar la relación que existe entre las variables que intervienen en la detección de fugas es necesario su modelamiento por esto es que se desarrolla la tesis intitulada "REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA".

Los Autores

RESUMEN

El tema central de esta investigación inédita tiene como premisa un recurso natural del cual Lima carece que es el agua potable, estamos enclavados en un desierto y esto conlleva a que los servicios de procesamiento y distribución de este sean insuficientes para satisfacer la demanda, esto sumado al desperdicio del agua no facturada ya sea por un deficiente sistema de redes de agua potable o por conexiones clandestinas hace urgente buscar soluciones a esta problemática.

Una fuga es una salida de agua no controlada en cualquiera de los componentes del sistema de distribución de agua potable; con mayor frecuencia ocurren en uniones de tuberías, codos, roturas de conductos y válvulas.

En algunos países, las fugas de los sistemas de abastecimiento de agua llegan a ser del 50% de la cantidad requerida por los habitantes para satisfacer sus necesidades hídricas; esto implica pérdidas económicas de importancia y un mal aprovechamiento de los recursos naturales.

Es por eso que se desarrolló la Tesis "REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA" que consiste en aplicar las redes neuronales con ayuda del software MATLAB para resolver un problema puntual que es la detección y clasificación de las fugas en tiempo real y con un margen de error menor con respecto al error humano.

Esto conllevará a un ahorro porcentual del agua potable no facturada por parte de la empresa prestadora del servicio al hacer la detección de las fugas no visibles más eficiente y rápida.

RESUMO

O tema central desta pesquisa inédita tem como premissa um recurso natural que Lima não tem que é água potável, são aninhado em um deserto e isso leva a serviços de processamento e distribuição deste são insuficientes para atender a demanda, acrescentou as águas residuais não faturada, quer por um sistema deficiente de água potável ou ligações clandestinas é urgente encontrar soluções para este problema.

Um vazamento é uma saída de água descontrolada em qualquer um dos componentes do sistema de distribuição de água potável; mais frequentemente eles ocorrem nas articulações de tubos, cotovelos, tubos quebrados e válvulas.

Em alguns países, os vazamentos dos sistemas de abastecimento de água chegam a 50% do valor exigido pelos habitantes para atender às suas necessidades de água; isso implica perdas econômicas significativas e um uso inadequado dos recursos naturais.

É por isso que a tese "REDES NEURAIAS ARTIFICIAIS APLICADA A VAZAR NÃO VISÍVEL EM REDES DE ÁGUA DA CIDADE LIMA", que envolve a aplicação de redes neurais utilizando o software Matlab para resolver um problema específico desenvolvido que é a detecção e classificação de vazamentos em tempo real e com menor margem de erro em relação ao erro humano.

Isto levará a uma percentagem de poupança de água não faturada pela companhia que presta o serviço para detectar o mais eficiente e rápida Sem vazamentos visíveis.

“REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA”

CAPÍTULO - 1

1. PLANTEAMIENTO DE LA INVESTIGACION

El problema del desabastecimiento de agua potable para el consumo humano es un desafío para las futuras generaciones, la población a nivel mundial aumenta y en contraste los recursos hídricos son más escasos año con año.

Sólo muy poca agua es utilizada para el consumo del hombre, ya que: el 90 % es agua de mar y tiene sal, el 2 % es hielo y está en los polos, y sólo el 1 % de toda el agua del planeta es dulce, encontrándose en ríos, lagos y mantos subterráneos. Además, el agua tal como se encuentra en la naturaleza, para ser utilizada sin riesgo para el consumo humano requiere ser tratada, para eliminar las partículas y organismos que pueden ser dañinos para la salud. Y finalmente debe ser distribuida a través de tuberías hasta las casas, para que se pueda consumir sin ningún problema ni riesgo alguno.

En el caso peruano las empresas de distribución de agua son las encargadas del proceso de potabilización de agua, en el caso específico de la ciudad de Lima, la empresa prestadora del servicio es la estatal SEDAPAL desde hace 55 años.

Sedapal tiene que velar por la calidad del servicio ofrecido, sin embargo, esto se ve perjudicado sustancialmente por las fugas de agua potable no facturadas, (del medidor a la red) las cuales podrían ser detectadas más fácilmente con el modelamiento inteligente para la detección de las fugas no visibles de agua potable para con ello reducir la cantidad de agua no facturada debido a las pérdidas en tuberías y lograr mejorar el abastecimiento de agua potable en la ciudad de Lima.

1.1 Determinación del problema

SEDAPAL como empresa prestadora del servicio de distribución de agua potable es la responsable de velar por el abastecimiento del líquido elemento en la ciudad de Lima, los usuarios por su parte son responsables de mantener sus fábricas, universidades, colegios, oficinas, domicilios, cisternas de agua, etc. sin desperfectos en sus tuberías, conexiones y accesorios para evitar el despilfarro de agua innecesariamente y evitar así los montos elevados en la facturación de los recibos a fin de mes y el posible desabastecimiento generado por dichos desperfectos.

Son más de 14000 km de tuberías de agua potable distribuidas en la gran Lima las cuales por su longitud, por su antigüedad y múltiples factores más; son vulnerables a sufrir desperfectos llámese averías las cuales implican pérdidas sustanciales de agua potable las cuales afectan el normal abastecimiento por parte de SEDAPAL, estas averías pueden según su magnitud de fuga de agua: pequeñas, medianas, grandes y a veces enormes cuando las tuberías afectadas son tuberías matrices o principales ocasionando cortes en el suministro de agua en distritos completos.

"REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA" se toma como parte de una estrategia de mejoramiento del proceso de detección y clasificación de fugas no visibles en la ciudad de Lima.

Actualmente observamos que el proceso se realiza de forma manual con personal calificado que realiza esa labor la cual presenta deficiencias (errores) debido a factores diversos, entre ellos: el ruido ambiental, capacitación del personal, factores humanos, etc.

En el sistema de distribución de agua potable externo al usuario existe una gran cantidad de situaciones que pueden llevar al desabastecimiento, en términos generales se pueden presentar: fallas temporales, permanentes, fallas operacionales y problemas de índole natural: huaycos, lluvias, sequías, etc.

Es por eso que viendo esta problemática con respecto a el abastecimiento de agua potable se plantea el diseño de un sistema de control inteligente que permitirá ejecutar este proceso de la detección de fugas en forma más eficiente y con un menor margen de error.

1.2 Formulación del problema

1.2.1 Problema General

El reconocimiento o formulación del problema objeto de investigación, primordialmente se refiere a la selección general del problema enmarcado en las dimensiones epistemológicas que gobiernan las ciencias de la ingeniería electrónica, consecuentemente, del problema general ser desmembrados en problemas específicos a ser investigados con sus correspondientes sub objetivos y sub hipótesis de solución a dichos problemas.

La selección general del problema objeto de investigación, se justifica desmembrar o fragmentar de forma lógica mental en problemas específicos coherentes a las dimensiones que gobiernan las Ciencias de la Ingeniería Electrónica, correspondientes en:

- Programas de Investigación
- Sub Programas de Investigación y en
- Líneas de Investigación

Para la selección general del problema objeto de investigación, es necesario formular la siguiente interrogante:

¿Será posible utilizar un algoritmo con Redes Neuronales Artificiales en MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima?

1.2.2. Problemas específicos

Para mayor fidelidad sobre la detección de fugas no visibles, es indispensable desmembrar coherentemente del principal problema objeto de investigación, en sub problemas específicos formulando las siguientes interrogantes:

- ¿Será instaurado el equipo localizador inteligente para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima reduciendo los porcentajes de agua no facturada?
- ¿Se podrá determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima?

1.3 Objetivos de la investigación

1.3.1 Objetivo General

Un modelo inteligente haciendo uso Redes Neuronales Artificiales con MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.

1.3.2 Objetivo Específicos

Para definir los objetivos específicos del problema objeto de investigación, es necesario desmembrar del objetivo principal, en los siguientes objetivos específicos:

- Emplear un equipo localizador inteligente para la detección de los sonidos de las fugas no visibles en las redes de agua potable en la ciudad de lima reduciendo los porcentajes de agua no facturada por la empresa prestadora del servicio.
- Determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima

1.4 Justificación

- El utilizar Modelamiento en Redes Neuronales Artificiales con MATLAB para detectar fugas no visibles en las redes de agua potable de la ciudad de Lima se justifica por la necesidad de mejorar el proceso de detección de fugas no visibles.
- La actual evolución de la tecnología permite que se puedan diseñar sistemas de este tipo y ayudar a la optimización del servicio.
- Socialmente se justifica, toda vez que el desarrollo de esta tecnología permitirá mejoras en el servicio de detección de fugas no visibles y su aplicación a mayor escala.
- Este desarrollo permitirá su implementación para muchos otros campos de la industria en los cuales se necesita detectar fugas no visibles.

CAPÍTULO - 2

2 MARCO TEORICO

2.1 Antecedentes del Estudio

En el “estado del arte de búsqueda de la información” para el desarrollo de la presente investigación, se ha acopiado informaciones relevantes, conjuntamente con los principios epistemológicos que gobiernan dimensionalmente las Ciencias de la Ingeniería Electrónica.

- Tesis Doctoral: Redes Neuronales Artificiales aplicadas al Análisis de Datos. Por Juan José Montaña Moreno. Universitat de Les Illes Balears. España 2002.
- Tesis de Maestría: Técnicas para mejorar el Reconocimiento de Voz en presencia de Habla fuera del Vocabulario. Por Heriberto Cuayáhuil Portilla. Universidad de las Américas de Puebla. México 2000.

- Tesis de Maestría: Modelo para cuantificar fugas en sectores hidrométricos de redes de agua potable. Por Nadir Fernanda López Gómez. Universidad Nacional Autónoma de México. México 2015.
- Tesis de Maestría: Método de detección y ubicación de fugas, en ductos de gran longitud, mediante velocidad de propagación de onda de presión negativa, en ductos con mediciones de presión multipunto. Por Jhony Alexander Calderón Carrillo. Instituto Tecnológico y de Estudios Superiores de Monterrey. México 2012.

2.2 Marco Conceptual

El Marco filosófico de la presente investigación es de suma importancia, por tratarse de la detección de fugas no visibles en las redes de agua potable, el agua recurso natural sin el cual no existiría la vida; amparándose en tres ejes filosóficos como son: lo ontológico sobre la concepción del ser humano generando el compromiso de asumir fundamentalmente el mejoramiento de la calidad de vida de las personas. De igual manera, en lo metodológico aplicando nuevos métodos, técnicas y/o estrategias para la solución total de los problemas y en lo epistemológico que trata la parte doctrinaria que toda investigación tiene y que se concibe en el "cómo debe de ser" la solución al problema objeto de investigación.

2.2.1 Fundamentación ontológica

La ontología como parte de la filosofía trata sobre el "universo del ser" valorar el recurso en este caso que se desea preservar que es el agua potable evitando su desperdicio detectando a tiempo las fugas tanto a nivel comercial y residencial (Onto = ser, ente. Logo = estudio, ciencia, teoría), y como la principal responsabilidad del investigador científico es conocer, entender y sistematizar el problema objeto de estudio en este caso la detección de fugas no visibles de agua usando como herramienta las redes neuronales.

2.2.2 Fundamentación metodológica

En la presente investigación la fundamentación metodológica, se refiere al "universo del hacer", sobre el proceso de la detección de fugas no visibles usando las redes

neuronales como herramienta para hacer este proceso mas eficiente y menos propenso a los errores evitando el desperdicio de agua potable no facturada.

El concepto de Metodología hace referencia al plan de investigación que permite cumplir ciertos objetivos en el marco de una ciencia, por lo tanto, puede entenderse a la metodología como el conjunto de procedimientos que determinan una investigación de tipo científico o marcan el rumbo de una exposición doctrinal. El vocablo Metodología es generado a partir de tres palabras griegas: meta (más allá), odós (camino) y logos (estudio), sin embargo, es importante la distinción entre el método (nombre que recibe cada plan seleccionado para alcanzar un objetivo) y la metodología (rama que estudia el método).

2.2.3 Fundamentación Epistemológica

El sustantivo epistemología o gnoseología está compuesto por la unión de dos palabras griegas, episteme que se refiere al "conocimiento o ciencia" y logos como "discurso", concluyentemente, el fundamento epistemológico concierne al "universo del conocer" y la parte doctrinaria de esta investigación fundamentalmente experimental aplicada, radica en que los interesados en este caso la población en general deben saber el "cómo debe de ser" que se cuiden nuestros recursos naturales en este caso el agua potable con un sistema de detección de fugas eficiente que permita reducir estas en bien de todos.

Cuidar el medio ambiente es necesario, pues lo que ocurra en él afecta a todos los seres vivos que conviven en un mismo sistema.

Hablar del medio ambiente es un tema extenso, pues comprende – inicialmente – a todo lo que rodea a los seres vivos, y también implica variables que condicionan de forma importante a la sociedad y la cultura de los seres humanos, por ende, marca muchas veces el rumbo a seguir de las próximas generaciones. La palabra medio ambiente proviene del latin "medius" y "ambiens", las que en conjunto se enfocan hacia el concepto de "lo que está a ambos lados".

El cuidado del medio ambiente es tan importante, que se necesita de una preocupación exhaustiva por los detalles, debido a que es imposible conseguir un entorno adecuado, y el buen funcionamiento de los factores que le modifican, si no se cuidan las variables que son capaces de alterarlos. Un ejemplo del tema es el que se refiere a la contaminación de los ríos y mares convirtiéndose en una problemática mundial, por que estamos acabando con las fuentes naturales de agua para consumo humano, dentro de 50 años las guerras ya no serán por petróleo sino por el control de las reservas de agua potable del planeta.

2.2.4 Cuidado ambiental y política ambientalista

El índice de Desempeño Ambiental 2010 (Environmental Performance Index), realizado por Yale Center for Environment Law & Policy de la Universidad de Yale, en combinación al trabajo de la Universidad de Columbia (Center for International Earth Science Information Network), y la Comisión Europea en conjunto al World Economic Forum, clasificaron a un total de 163 países según el desempeño sobre distintas mediciones que eran categorizadas según: salud ambiental, calidad del aire, manejo de recursos, cambio climático, agricultura, biodiversidad, entre otros.

En este tipo de índices de medición se puede observar cómo la política ambientalista de los distintos países del mundo afecta al medio, influye en el desarrollo de la sociedad y la cultura, y decide en gran parte el futuro de las próximas generaciones.

"China es el país que más contamina el mundo en términos absolutos y Estados Unidos el que más contamina en términos relativos. ¿Qué hay de las energías limpias como la solar, geotérmica, eólica y demás? La respuesta es tan cruda como cruel: cuando el petróleo es barato, es barato ensuciar. El boom de las energías alternativas se disparó con un barril por encima de los 100 dólares. Sólo tendremos un mundo limpio cuando el petróleo sea caro, y convenga explorar alternativas más limpias. Si el petróleo baja de precio, tendremos un mundo cada vez más sucio. Así de sencillo".

Cuadro N°1
Países con más emisiones de CO2

Emisiones de CO2 (kilotones)			
	World	33.615.389	
1	China	8.286.892	24,7%
2	United States	5.433.057	16,2%
3	India	2.008.823	6,0%
4	Russian Federation	1.740.776	5,2%
5	Japan	1.170.715	3,5%
6	Germany	745.384	2,2%
7	Iran, Islamic Rep.	571.612	1,7%
8	Korea, Rep.	567.567	1,7%
9	Canada	499.137	1,5%
10	United Kingdom	493.505	1,5%
11	Saudi Arabia	464.481	1,4%
12	South Africa	460.124	1,4%
13	Mexico	443.674	1,3%
14	Indonesia	433.989	1,3%
15	Brazil	419.754	1,2%
16	Italy	406.307	1,2%
17	Australia	373.081	1,1%
18	France	361.273	1,1%
19	Poland	317.254	0,9%
20	Ukraine	304.805	0,9%

Fuente: Reporte Banco Mundial 2013

2.2.5 Medio Ambiente – Recursos Hídricos

El agua está en el centro del desarrollo sostenible y resulta fundamental para el desarrollo socio-económico, unos ecosistemas saludables y la supervivencia humana. El agua resulta vital a la hora de reducir la carga mundial de enfermedades y para mejorar la salud, el bienestar y la productividad de las poblaciones así como para la producción y la preservación de una serie de beneficios y servicios de los que gozan

las personas. El agua también está en el corazón de la adaptación al cambio climático, sirviendo de vínculo crucial entre el sistema climático, la sociedad humana y el medio ambiente.

El agua es un recurso limitado e insustituible que es clave para el bienestar humano y solo funciona como recurso renovable si está bien gestionado. Hoy en día, más de 1.700 millones de personas viven en cuencas fluviales en las que su uso supera la recarga natural, una tendencia que indica que dos tercios de la población mundial podría vivir en países con escasez de agua para 2025. El agua puede suponer un serio desafío para el desarrollo sostenible pero, gestionada de manera eficiente y equitativa, el agua puede jugar un papel facilitador clave en el fortalecimiento de la resiliencia de los sistemas sociales, económicos y ambientales a la luz de unos cambios rápidos e imprevisibles.

2.2.6 ¿Qué es el “desarrollo sostenible”?

El desarrollo sostenible se popularizó de manera explícita y contextualizada por la Comisión Brundtland en el documento “Nuestro Futuro Común” donde se define como “el desarrollo que satisface las necesidades del presente sin comprometer la capacidad de las generaciones futuras para atender sus propias necesidades” (ONU, 1987). La Comisión Brundtland se centró en tres pilares del bienestar humano: las condiciones económicas, sociopolíticas y ecológicas/ambientales. Este concepto básico fue desarrollado como apoyo a la implementación de medidas sólidas dirigidas a impulsar el desarrollo económico y social, en particular para las personas de los países en vías de desarrollo y, al mismo tiempo, garantizar que la integridad del medio ambiente se mantenga para las generaciones futuras.

Los Objetivos de Desarrollo del Milenio (ODM)

Los Objetivos de Desarrollo del Milenio (ODM), acordados en el año 2000, tienen el objetivo de reducir a la mitad la proporción de personas sin acceso sostenible a agua potable y a servicios básicos de saneamiento entre 1990 y 2015.

Un total de 748 millones de personas no tienen todavía acceso a una fuente mejorada de agua potable y los indicadores existentes no abordan cuestiones relacionadas con la seguridad y fiabilidad del suministro de agua. Se requieren mejoras reales para varios miles de millones de personas si se pretende lograr el derecho humano a un agua potable segura.

En julio de 2010, la Asamblea General de las Naciones Unidas adopta una resolución que "reconoce que el derecho al agua potable y el saneamiento es un derecho humano esencial para el pleno disfrute de la vida y de todos los derechos humanos" (A/RES/64/292).

La meta de los ODM sobre el saneamiento es un reto aún más apremiante: 2.500 millones de personas carecen actualmente de acceso a servicios de saneamiento mejorados y más de 1.000 millones todavía practican la defecación al aire libre. Al ritmo actual de progreso, la meta del saneamiento no será alcanzada por más 500 millones de personas.

Por otra parte, estas cifras globales ocultan grandes disparidades entre las naciones y las regiones, entre los ricos y los pobres, entre las poblaciones rurales y las urbanas, así como entre los grupos desfavorecidos y la población en general.

Actualmente no existe una meta mundial para mejorar la higiene, a pesar de ser una de las intervenciones de salud pública individuales más rentables.

2.2.7 Desarrollo sostenible y agua

La agricultura es, con diferencia, el mayor consumidor de agua a nivel mundial, representando el 70% de las extracciones de agua en todo el mundo, aunque esta cifra varía considerablemente entre países. La agricultura de secano es el sistema de producción agrícola predominante en todo el mundo y su productividad actual es, en promedio, un poco más de la mitad del potencial a obtener sobre una gestión agrícola óptima. Para 2050, la agricultura tendrá que producir un 60% más de alimentos a nivel mundial y un 100% más en los países en vías de desarrollo.

La industria y la energía juntas representan el 20% de la demanda de agua. Los países más desarrollados tienen una proporción mucho mayor de extracciones de agua dulce para la industria que los países menos desarrollados, donde predomina la agricultura. El equilibrio entre los requisitos de sostenibilidad frente a la visión convencional de la producción industrial en masa crea una serie de interrogantes para la industria. A gran escala, la globalización y la forma de extender los beneficios de la industrialización a todo el mundo equitativamente y sin impactos insostenibles sobre el agua y otros recursos naturales es la cuestión clave.

El sector doméstico representa el 10% del uso total de agua. Y, en todo el mundo, se estima que 748 millones de personas siguen sin tener acceso a una fuente mejorada de agua y que 2.500 millones siguen sin acceso a unos servicios de saneamiento mejorados.

Ciudades. Más de la mitad de la población ya vive en áreas urbanas y, para 2050, se espera que más de dos tercios de una población mundial de 9.000 millones viva en ciudades. Por otra parte, la mayor parte de este crecimiento ocurrirá en los países en vías de desarrollo, que tienen una capacidad limitada para hacer frente a estos rápidos cambios. El crecimiento también dará lugar a un aumento del número de personas que viven en barrios marginales y que suelen sufrir unas condiciones de vida muy pobres, sin acceso o con un acceso inadecuado a agua y saneamiento. Por lo tanto, el desarrollo de los recursos hídricos para el crecimiento económico, la equidad social y la sostenibilidad ambiental está estrechamente vinculado con el desarrollo sostenible de las ciudades.

Los ecosistemas. Quizás el reto más importante para el desarrollo sostenible que ha surgido en las últimas décadas es el alcance de la crisis ecológica global, que se está convirtiendo en una barrera para el desarrollo humano. Desde el punto de vista ecológico, los esfuerzos para un desarrollo sostenible no han tenido éxito. La degradación del medio ambiente mundial ha alcanzado un nivel crítico, con los principales ecosistemas acercándose a límites que podrían desencadenar un colapso masivo. La creciente comprensión de los límites planetarios globales, que deben ser

respetados para proteger los sistemas de soporte de la vida de la Tierra, tiene que ser la base del futuro marco de desarrollo sostenible.

2.2.8 Recursos Hídricos

Lo primero que hay que definir antes de entrar en la definición de recursos hídricos es conocer su origen etimológico:

-Recursos es una palabra cuya raíz es el latín "recursus", que viene a hacer referencia a hacer uso de los medios o bienes de los que dispone alguien para acometer algo en concreto.

-Hídricos, por su parte, emana del griego. Puede traducirse como "relativo al agua" y es fruto de la suma de dos partes claramente diferenciadas: el sustantivo "hydor", que es sinónimo de "agua", y el sufijo "-ico", que se usa para indicar "relativo a".

Un recurso es una materia prima o un bien que dispone de una utilidad en pos de un objetivo. Por lo general se trata de algo que satisface una necesidad o que permite la subsistencia. Hídrico, por su parte, es aquello que está vinculado al agua.

Los recursos hídricos son los cuerpos de agua que existen en el planeta, desde los océanos hasta los ríos pasando por los lagos, los arroyos y las lagunas. Estos recursos deben preservarse y utilizarse de forma racional ya que son indispensables para la existencia de la vida.

El problema es que, aunque en su mayoría son recursos renovables, la sobreexplotación y la contaminación que provocan diversas actividades humanas hacen que los recursos hídricos estén en riesgo. Su capacidad de regeneración muchas veces no resulta suficiente ante el ritmo de uso.

Una de las grandes dificultades que enfrenta la Humanidad es la falta de agua dulce. Más del 97% del agua de la Tierra es agua salada, cuyo aprovechamiento es complejo. Por eso el agua dulce, que se utiliza para el consumo humano y un sinnúmero de actividades, es tan importante.

En concreto, las estimaciones llevadas a cabo vienen a establecer que el 100 % del agua total del planeta se distribuye de la siguiente manera: 97,47 % de agua salina, 2,53 % de agua dulce, 1,76 % de glaciares y capas polares, 0,76 % de agua subterránea y 0,01 % de lagos, ríos y atmósfera.

La construcción de presas y el tratamiento de aguas residuales son algunas de las estrategias que se llevan a cabo para obtener recursos hídricos que puedan aprovecharse. El desafío es que todo aquello que se realiza para conservar el agua dulce resulte suficiente para contrarrestar el abuso y la eliminación de ésta.

Además de todo lo expuesto, no podemos pasar por alto que los expertos coinciden en subrayar que otro de los grandes problemas que presentan los recursos hídricos en la actualidad es la contaminación que están sufriendo, como consecuencia de diversos actos del ser humano como sería el caso de los vertidos. Por ese motivo, se han puesto en marcha distintas iniciativas y se apuesta por tomar medidas, tales como la creación de plantas de tratamiento de aguas residuales, creación de órganos de control, evitar el consumo de productos industriales.

Uno de los principales problemas que enfrenta el mundo en un futuro cercano es la disminución del suministro de agua hasta en un 40 % para el año 2030, por lo que es importante mejorar considerablemente la gestión de este recurso.

El agua cada vez se está convirtiendo en un recurso escaso debido a diferentes factores como la deforestación, el mal uso del agua y el calentamiento global. Se prevé que en el 2030 el Perú empezará a sentir seriamente los estragos de la falta de agua, sobre todo por la desigual distribución de los recursos hídricos.

Según datos del Ministerio del Ambiente, en la vertiente amazónica reside el 26 % de la población, que cuenta con el 97,7 % de agua, mientras que en la vertiente del Pacífico reside el 70 % de la población, que cuenta tan solo con el 1,8 % de agua.

Los recursos y servicios relacionados con el agua son esenciales para el logro de la sostenibilidad global, puesto que estos ayudan al crecimiento económico, la reducción de la pobreza y la sostenibilidad ambiental.

2.2.9 Políticas de Manejo del Agua Potable

Lima es la segunda ciudad en el mundo afincada en un desierto después del Cairo en Egipto, por lo que los recursos hídricos que poseemos son insuficientes y lo serán más en los próximos años.

Es necesario por ello hacer un uso adecuado de las fuentes de agua (en nuestro caso de las fuentes de agua potable de la ciudad de Lima)

El Decreto Supremo N° 006-2015-MINAGRI y 013-2015-MINAGRI aprobaron la Política y Estrategia Nacional de Recurso Hídricos y el plan Nacional de Recursos Hídricos respectivamente.

Determinando que la Planificación de los Recursos Hídricos tiene por objeto promover su uso sostenible, equilibrar la oferta con la demanda de agua, la conservación y la protección de la calidad de las fuentes naturales en armonía con el desarrollo nacional, regional y local, así como la protección e incremento de la cantidad de la disponibilidad de agua.

En el sector de agua potable y saneamiento del Perú, se han logrado importantes avances en las últimas dos décadas del siglo XX y primera del siglo XXI, como el aumento del acceso de agua potable del 30% al 62% ocurrido entre los años 1980 al 2004 y el incremento del acceso de saneamiento del 9% al 30% entre los años 1985 al 2004 en las áreas rurales. Asimismo, se han logrado avances en la desinfección del agua potable y el tratamiento de aguas negras.

En el año 1981 el gobierno de Fernando Belaúnde Terry fusionó las tres Empresas de Saneamiento de Lima, Arequipa y Trujillo y la fusionó en una sola empresa estatal matriz: el Servicio Nacional de Abastecimiento de Agua y Alcantarillado (SENAPA). El SENAPA estaba conformado por 15 empresas filiales y 10 unidades operativas distribuidas a lo largo del país. SEDAPAL en Lima era la más grande de estas empresas filiales estatales. Sin embargo, 200 ciudades (20%) quedaron afuera del SENAPA y administraron sus propios servicios.

2.2.6 Sedapal

El Servicio de Agua Potable y Alcantarillado de Lima - Sedapal S.A. (SEDAPAL), es una empresa estatal peruana creada en 1981.

Brinda prestaciones de agua potable y alcantarillado al sector urbano de la ciudad de Lima. SEDAPAL gestiona el abastecimiento de agua potable del área metropolitana de Lima y Callao.

El agua que suministra está tratada en La Atarjea en El Agustino que abastece a más de 9 millones de habitantes de Lima.

a. Objetivos de Sedapal

- El objetivo de Sedapal es la prestación de los servicios de saneamiento como agua potable y alcantarillado sanitario.
- Ejecuta la política del sector en la operación, mantenimiento, control y desarrollo de los servicios básicos, con funciones específicas en aspectos de normatividad, planeamiento, programación,
- Elaboración de proyectos, financiación, ejecución de obras, asesoría y asistencia técnica.
- Además, puede dedicarse a otras actividades afines, vinculadas, conexas y/o complementarias a su objeto social.

b. Servicios de Saneamiento

- Instalación y reubicación de conexiones domiciliarias
- Revisión y aprobación de proyectos
- Supervisión de obras
- Empalmes a la red existente
- Cierre y reapertura de conexiones
- Inspecciones en las redes primarias de agua potable, detección de fugas
- Factibilidad de servicios para habilitaciones urbanas

- Otros que determine la Superintendencia

c. Servicio de Detección de Fugas no visibles en redes primarias (ECRF)

La finalidad pública del presente servicio está relacionada con el objetivo de primer nivel "Disminuir el Agua No Facturada" y el objetivo de segundo nivel "Reducir los volúmenes de pérdidas de agua potable"; lo que permitirá reducir las pérdidas de agua y brindar un mejor servicio.

El presente servicio lo ejecuta El Equipo Control y Reducción de Fugas (ECRF) de la Gerencia de Producción y Distribución Primaria de SEDAPAL.

Para la realización de estas labores se cuentan con 5 unidades móviles las cuales se desplazan por la ciudad de Lima, realizando labores diversas como:

- Inspección de Redes Primarias de Agua Potable según programación establecida con anticipación.
- Detección de fugas imprevistas en calles y avenidas.
- Detección de conexiones clandestinas de agua.
- *Monitoreo de la presión de agua (psi) por cuadrantes y/o zonas.

Para la realización de las actividades diarias, las unidades cuentan con instrumental especializado tanto digital como analógico.

Este equipo se utiliza para las labores de detección de fugas de agua, obstrucción de tuberías, tuberías clandestinas y así como para controlar la presión de agua en la red de tuberías.

El personal de cada unidad ha recibido entrenamiento especial para el manejo y la operación de estos equipos (por lo general para el servicio se cuenta con personal con una experiencia no menor a 5 años dado el tipo de labor que se realiza)

Cada unidad móvil cuenta con 5 personas (Técnico, Operario especializado, Chofer y 2 operarios).

Figura N° 1
Unidad Móvil Detección de Fugas




Fuente: propia del autor

2.2.11 Equipos utilizados por el (ECRF)

Para realizar su labor el ECRF cuenta con equipos electrónicos portátiles de última generación los cuales les permiten realizar su labor en forma eficiente.

Antiguamente para reparar una tubería matriz con fuga se tenía que excavar toda la cuadra ya que no se contaba con equipos para detectar la zona de la tubería averiada, esto repercutía en problemas de logística (cerrar las calles alédañas, redirigir el tráfico de vehículos, cortar el suministro de agua de toda la zona, etc.). Las reparaciones podían durar días y hasta incluso semanas.

Figura N° 2
Instalación de Tubería Matriz



Fuente: propia del autor


Es por ello importante resaltar lo importante que es contar con estos equipos en la actualidad para poder así reparar las tuberías en cuestión de horas, gracias a la localización exacta del tramo de tubería dañado.

a. Manómetro

El manómetro (del gr. $\mu\alpha\nu\acute{o}\varsigma$, ligero y $\mu\acute{\epsilon}\tau\rho\nu$, medida) es un instrumento de medición para la presión de fluidos contenidos en recipientes cerrados. Se distinguen dos tipos de manómetros, según se empleen para medir la presión de líquidos o de gases.

Figura N° 3

Manómetro de Glicerina para Fluidos presurizados



Fuente: propia del autor

Las unidades que más se utilizan en manómetros para fluidos PSI, Mpa y Bar.

- PSI = Libras por pulgada cuadrada
- Mpa = Megapascal

- Bar = 1 Atmosfera = 1000000 de barias

Tabla N° 1

1 Bar	0.1 Megapascal	14.5038 psi
-------	----------------	-------------

Fuente: propia del autor

Este tipo de instrumentos funcionan de la misma forma que un manómetro convencional, pero con la diferencia de que poseen glicerina.

La función de la glicerina es proteger el mecanismo interno del manómetro; este relleno brinda estabilidad a la aguja indicadora, una vez que el instrumento ha sido instalado en zonas de vibraciones.

Cuando un manómetro no posee glicerina, este puede no funcionar de la forma correcta, provocando que se atore la aguja y obteniendo mediciones alteradas.

Asimismo, es importante señalar que si el manómetro posee una filtración de aceite en la caratula, es mejor cambiarlo, ya que esta fisura, también, provocaría que se logre una medición errónea.

Los manómetros de glicerina pueden ser rellenos con glicerina para baja temperatura o silicona, cualesquiera de las dos opciones brindarán la protección adecuada al equipo.

Los manómetros con glicerina son realmente útiles en aplicaciones donde intervenga:

- Aire
- Agua
- Aceite
- Fluidos compatibles con la conexión y mecanismo
- Sistemas hidráulicos

- Sistemas oleo hidráulicos
 - Turbinas
 - Motores
 - Uso industria (donde haya vibración y golpes)

Existen diferentes aplicaciones y modelos de manómetros, los utilizados en (ECRF) son del tipo de metal con relleno de glicerina y se utilizan para las labores de toma de presión en los medidores domésticos, la presión para la ciudad de Lima oscila entre 20 y 65 psi, el rango mínimo de presión que se necesita para poder realizar trabajos de detección de fugas es de 10 psi, debajo de ese valor no se puede realizar trabajos de detección de fugas.

Una hoja de datos técnicos del manómetro utilizado por el ECRF

Figura N° 4

Manómetro de Glicerina especificaciones técnicas

**Manómetro con muelle tubular
Modelo 213.63, Líquido de relleno, Caja acero Inoxidable**

Homologación WIRA PM 02.12

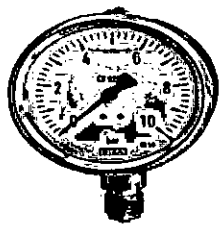
GL EAC otras homologaciones véase página 2

Aplicaciones

- Para puntos de medida con elevadas cargas dinámicas y vibraciones
- Para medidas gaseosas, líquidas, no viscosas y no cristalizantes, compatibles con aleaciones de cobre
- Hidráulica
- Compresores, industria naval

Características

- Resistente contra vibraciones y golpes
- Construcción de extrema robustez
- DN 63 y 100 con homologación Germanischer Lloyd y DNV
- Rango de indicación hasta 0 ... 1,000 bar



Descripción

Verstén
EN 837-1

Díametro en mm
50, 63, 100

Clase de exactitud
DN 50, 63: 1,6
DN 100: 1,0

Rangos de indicación
DN 50: 0 ... 1 a 0 ... 400 bar
DN 63, 100: 0 ... 0,6 a 0 ... 1,000 bar
ver como todas las gamas correspondientes para presión negativa y sobrepresión negativa y positiva

Carga de presión máxima
DN 50, 63: Carga estática: 3M x valor final de escala
Carga dinámica: 2,3 x valor final de escala
Pulsat: valor final de escala
DN 100: Carga estática: valor final de escala
Carga dinámica: 0,6 x valor final de escala
Pulsat: 1,3 x valor final de escala

Temperatura admisible
Ambiente: -20 ... +60 °C
Medio: máx. +20 °C

Influencia de temperatura
En caso de desviación de la temperatura de referencia en el sistema de medición (+20 °C): máx. ±0,4 %/10 K de la gama de indicación

Tipo de protección
IP 65 según EN 60529 / IEC 60529

Manómetro con muelle tubular, modelo 213.63.100, permeación interior

Fuente: propia del autor

b. Geófono

El Geófono, es un detector de pérdidas de fugas de agua localiza con precisión fugas subterráneas. Elimina costos de excavaciones y reduce tiempos en la localización de fugas.

2.1.12 Geófonos Mecánicos

Los geófonos son mecánicos y electrónicos, operan con el principio de sismógrafo. Son extremadamente sensibles. Un operador experimentado de geófonos puede incluso determinar el tamaño de una fuga con gran precisión.


Muchas empresas distribuidoras de aguas y plantas industriales están utilizando con éxito este instrumento para detectar fugas de aguas subterráneas.

El principio de funcionamiento se basa en que los "auriculares" son colocados en el piso, siendo éstos muy sensibles. Estos recogen el sonido de las vibraciones, estos son amplificados por el instrumento y se transmitirán al auricular del operador.

El más leve goteo se puede escuchar y se puede rastrear este moviendo los "auriculares de piso" hasta encontrar el punto de máximo sonido.

Figura N° 5

Geófono de piso mecánico, muy similar a un estetoscopio



Fuente: propia del autor

2.2.13 Geófonos Electrónicos

Se cuenta con Geófonos Electrónicos para la escucha de las fugas en las tuberías y son de 2 tipos:

a. Geófono Lmic


La sencillez en el manejo del LMIC®, así como la doble funcionalidad de varilla de escucha para válvulas, acometidas y terrenos blandos, y el sensor de escucha para terrenos duros, permiten a este equipo obtener importantes prestaciones en detección de fugas con una muy interesante relación calidad-precio.

El LMIC® está provisto de un sensor de amplificación que posibilita detectar ruidos de fuga que el oído humano no es capaz de escuchar. Los auriculares disponen de control de volumen independiente y se conectan directamente al módulo sensor, que incorpora la electrónica y la batería.

Presionando un simple botón, el usuario activa el sistema para su escucha. Una vez se deja de presionar, el circuito de alimentación se desactiva.

Figura N° 6

Geófono electrónico LMIC



Fuente: propia del autor


b. Geófono Xmic

El Xmic es un geófono, muy avanzado en tecnología, diseñado para amplificar el ruido que genera el agua que escapa de las tuberías, en situaciones de fuga. Al identificar la posición del ruido de fuga más agudo, estaremos en presencia de la fuga propiamente tal.

Este geófono está compuesto por un módulo amplificador, muy liviano, con un cargador de baterías integrado, un set de audífonos con calidad HI-FI y un sensor de superficie para la escucha del suelo.

El Xmic es un geófono muy avanzado y de fácil uso. Posee lo último en tecnología de amplificación acústica, entregando excelente calidad en sonido, mientras una gran cantidad de características propias del Xmic ayudan en la localización eficaz y precisa de las fugas en el terreno.

Figura N°7
Geófono electrónico XMIC



Fuente: Cortesía PALMER INC

Figura N°8

Correcto uso de los Geófonos electrónicos XMIC y Lmic



Fuente: Cortesía PALMER INC

2.2.14 Correlador

Los Correladores son poderosos dispositivos electrónicos de localización de fugas en tuberías a presión, donde la ubicación aproximada de la fuga se desconoce y las distancias son relativamente altas. Dos (o más) sensores se colocan en contacto con la tubería a ambos lados de la fuga sospechada. Esos sensores registran y transmiten el sonido por radio a la unidad de procesamiento. Algoritmos matemáticos se utilizan para determinar la ubicación exacta de ciertos perfiles de ruido (por ejemplo, silbido de una fuga) en la tubería, mediante la correlación de los ruidos que llegan a los dos sensores y midiendo la diferencia del viaje del sonido en la tubería desde la fuga hacia cada sensor.

Existen Correladores que hacen la correlación en tiempo real y en otros modelos es necesario descargar la información a una pc y recién de ahí hacer la correlación


EL principio de la correlación está definido por $L = \frac{1}{2} (D - V \times Td)$

V= Velocidad del sonido dentro de la tubería

Td = Diferencia de la velocidad del sonido entre uno y otro sensor

Figura N° 9

Funcionamiento Correlador Palmer



Fuente: Cortesía PALMER INC

a. Correlador electrónico Palmer Micro Call+ (Correlación en tiempo real)

Correlador Palmer (1)

Radios Transmisoras de Señal (2,3 y 4)

Audífonos Estéreo HI-FI

Sensores de Audio (6 y 7)

Figura N° 10

Correlador Palmer +




Fuente: Cortesía PALMER INC

Se utiliza para detectar fugas de agua No visibles haciendo uso de sus 2 o 3 sensores, instalados intercaladamente en las conexiones domiciliarias.

Se conectan a la unidad central vía ondas de radio (FM) y esta da la posición aproximada de la tubería rota.

Figura N° 11
Correlador Palmer + en funcionamiento




Fuente: Cortesía PALMER INC

b. EL Correlador electrónico Aquascan 610 (Correlación en tiempo real)

- Correlador AquaScan (1)
- Radios Transmisoras de Señal (2 y 3)
- Audífonos Estéreo Bluetooth

- Sensores de Audio (2 y 3)

Figura N° 12
Correlador AquaScan en funcionamiento




Fuente: Gutermann INC

c. Correlador electrónico Multipunto Soundsens (No es en tiempo real)

- Correlador Soundsens (1)
- Radios Transmisoras de Señal (2)
- Audífonos Estéreo HI-FI
- Computadora

- Se obtiene una mejor respuesta por que se utilizan más de 3 sensores

Figura N° 13
Correlador Soundsens



Fuente: propia del autor

Soundsens, ha sido diseñado con lo último en software y hardware para entregar los más altos resultados, versatilidad y rapidez al utilizarse en campo.

Los operadores pueden programar y descargar los datos del equipo, sin la necesidad de un computador. La unidad es capaz de almacenar semanas de datos antes de ser descargados éstos a un PC, facilitando las operaciones en campo. Los sensores se descargan a través de señales infra-rojas, por lo que no hay necesidad de conexión directa física a través de cables. Todo esto hace que la instalación y descarga de datos, sea mucho más sencilla.

Más maletas pueden ser interconectadas, para permitir la descarga o programación simultánea de todos los equipos existentes. Esto, combinado con

una conexión USB para comunicación con el computador personal (PC), hace al proceso de detección de fugas algo completamente rápido y eficiente.

Cuadro N° 2 Correlador Soundsens Especificaciones


Sensor de Estrada		Acelerómetro interno de Alto Rendimiento para recoger todos los ruidos audibles de las tuberías
	Anclaje del logger / Sensor	Poderoso magneto de anclaje para instalación de los loggers en tuberías / válvulas
Características del Registrador	Memoria	Grabación de 650,000 lecturas (memoria expandible a 1,35 millones de lecturas de acuerdo a requerimiento) Registros individuales pueden ser pre-programados en series de 32 registros individuales.
	Frecuencia de muestreo	Ajustable por el usuario
	Inicio Retardado	Comienzo a cualquier hora del día o posterior a un periodo de tiempo ajustado, por ejemplo, para correlaciones nocturnas sin supervisión.
	ID del Logger	Número de ID programado de fábrica Además, se puede introducir otro ID para facilitar el reconocimiento por parte de los operadores
	Reloj	Incorporado, de 24 horas, en tiempo real con asignación de fecha
	Software	Compatible con el software de análisis de Radcom, Sound Sens
Comunicaciones	Mañeta a PC	A través de conexión USB para descarga rápida de datos
	Mañeta a Loggers	Comunicación simultánea desde los loggers a la maleta, vía Infra-rojo
	Mañeta a Maleta	Vía cable RS232 de 9 pin
Equipo	Dimensiones	Logger avanzado de correlación, con dimensiones reducidas: 160 Alto (incluido magneto) x 55Diam. mm (6.3A x 2.100")
	Construcción	Logger: Carcasa de aluminio, cubierta con pintura spray en polvo Maleta de Transporte: Estructura resistente con revestimiento de aluminio
	Peso	Cada logger correlador: 0.7 kg (1.54 lb)
	Maleta de transporte	Versiones de 2 - 4 loggers o de 6 - 8 loggers (Dos maletas pueden interconectarse)
	Temp. de Trabajo	-10 a +50°C (14 a +122°F)
	Protección Ambiental	Individual Correlator Pois: IP68 submersible
	Energía	Loggers de correlación tienen baterías de Ion-Liño, operativas hasta por 5 años en condiciones normales de trabajo. Maleta de Transporte contiene baterías de NiCad que deben ser cargadas aproximadamente una vez por mes o menos. Junto con el kit, se suministra un cable de conexión a la red eléctrica (transformador 110v/220v incluido en el producto).

Fuente: propia del autor

Con una vida típica de baterías de 5 años, pantalla LCD con luz de fondo y una simple interfaz, Soundsens está listo para ser usado como Correlador portátil

diurno o Correlador fijo durante la noche (ideal para sectores con fugas difíciles de encontrar).

Figura N° 14
Software Correlador Soundsens



Fuente: propia del autor

2.2.15 Redes Neuronales Artificiales

Explicaremos los principales conceptos teóricos relacionados con las Redes Neuronales Artificiales, iniciando con un breve recuento de los acontecimientos históricos que marcaron sus orígenes y evolución, para seguidamente dar paso a algunas definiciones

formales, el modelo biológico en el cual está basada su teoría, los elementos característicos que las componen, los principales tipos y arquitecturas de red conocidos y los mecanismos de aprendizaje y entrenamiento comúnmente utilizados en su diseño e implementación.

a. Panorama histórico

El diseño y construcción de máquinas que puedan realizar acciones "inteligentes" ha sido una de las principales preocupaciones científicas a través de los últimos años. A partir de numerosos aportes se han llegado a sentar las bases fundamentales para la construcción de máquinas con cierto grado de inteligencia. Se resumen a continuación los principales acontecimientos que han marcado la evolución de esta rama.

En el año de 1936, Alan Turing fue el primer investigador en estudiar el cerebro desde un punto de vista computacional. 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, propusieron una teoría acerca de la forma en que funcionan las neuronas. Ellos modelaron una red neuronal simple mediante circuitos eléctricos. Unos años después en 1949, Donald Hebb escribe un libro que fue importante en los inicios de la computación neuronal, La organización del comportamiento, en el que se establece una conexión entre la psicología y la fisiología [HileraOO].

En 1957, Frank Rosenblatt comienza con el desarrollo del perceptrón, conocido hoy como la más antigua red neuronal, y que se utiliza aún hoy en algunas aplicaciones de reconocimiento de patrones. Este modelo podía ya generalizar, es decir, luego de haber aprendido una serie de patrones era capaz de reconocer otros similares, aunque no se le hubieran presentado con anterioridad. Sin embargo, tenía una serie de limitaciones, quizá la más conocida era su

incapacidad para resolver el problema de la función OR-exclusiva y, en general no era capaz de clasificar clases no separables linealmente.

En 1959, Bernard Widrow y Macial Hoff, de la Universidad de Stanford, desarrollaron el modelo ADALINE (ADaptative LINear Elementé). Esta fue la primera red neuronal artificial aplicada a la resolución de un problema real (filtros adaptativos para eliminar ecos en las líneas telefónicas) y fue utilizada comercialmente durante varias décadas.

Uno de los mayores investigadores en redes neuronales desde los años 60 hasta nuestros días es Stephen Grossberg (Universidad de Boston) quien, a partir de su extenso conocimiento fisiológico, ha escrito numerosos libros y desarrollado modelos de redes neuronales artificiales. Estudió los mecanismos de la percepción y la memoria y realizó en 1967 una red llamada Avalancha, que consistía de elementos discretos con actividad que varía con el tiempo y que satisfacen ecuaciones diferenciales continuas. Se utilizó para intentar resolver problemas tales como reconocimiento continuo del habla y aprendizaje del movimiento de los brazos de un robot.

En 1969 surgieron numerosas críticas que frenaron, hasta 1982, el crecimiento que estaba experimentando el campo de las redes neuronales artificiales. Marvin Minsky y Seymour Papert, del Instituto Tecnológico de Massachussets (MIT), publicaron el libro *Perceptrons*, que además de contener un análisis matemático detallado del perceptrón, consideraba que la extensión a perceptrones multinivel (el perceptrón original solo poseía una capa) era completamente estéril. Las limitaciones del perceptrón eran importantes, sobre todo su incapacidad de resolver muchos tipos de problemas. Muchas investigaciones dieron en este punto un nuevo giro hacia la inteligencia artificial.

Seguidamente, James Anderson desarrolló un modelo lineal llamado Asociador Lineal, que consistía de elementos integradores lineales (neuronas) que sumaban sus entradas. Este modelo se basa en el principio de que las conexiones entre neuronas son reforzadas cada vez que están activadas. Anderson diseñó una potente extensión del asociador lineal, llamada Brain-State-in-a-Box (BSB).

En Europa y Japón también se hacía investigación en este campo. Kunihiko Fukushima desarrolló el Neocognitrón, un modelo de red neuronal para el reconocimiento de

patrones visuales. Teuvo Kohonen, un ingeniero electrónico de la Universidad de Helsinki, desarrolló independientemente un modelo similar al de Anderson.

En 1982, coincidieron numerosos eventos que hicieron resurgir el interés por las redes neuronales. Jhon Hopfield presentó su trabajo sobre redes neuronales en la Academia Nacional de Ciencias. En el trabajo, describe con claridad y rigor matemático una red a la que ha dado su nombre, que es una variación del asociador lineal, pero además, mostró como tales redes pueden trabajar y qué pueden hacer. Además, en 1982 se celebró la U.S.-Japan Joint Conference on Cooperative/COmpetitive Neural Networks y Fujitsu comenzó el desarrollo de computadoras pensantes para aplicaciones en robótica.

En 1985, el Instituto Americano de Física comenzó lo que ha sido la reunión anual Neural Networks of Computing. Esta ha sido la primera de muchas otras. En 1987, la IEEE celebró la primera conferencia internacional sobre redes neuronales, con más de 1800 asistentes y 19 nuevos productos mostrados. En el mismo año se formó la Internacional Neural NetWork Society (INNN) bajo la iniciativa y dirección de Grossberg en U.S.A., Kohonen en Finlandia y Amari en Japón; y en menos de 2 años la INNN tenía más de 3000 socios. A partir de este momento, el interés por el área se ha incrementado de forma notable, contándose hoy en día con un gran número de congresos, reuniones científicas, revistas especializadas y el interés de un gran número de empresas en incorporar esta tecnología a una amplia gama de aplicaciones específicas.

Seguidamente se exponen las principales ideas en torno al modelo que ha servido de base para la teoría de las redes neuronales artificiales.

b. El modelo biológico

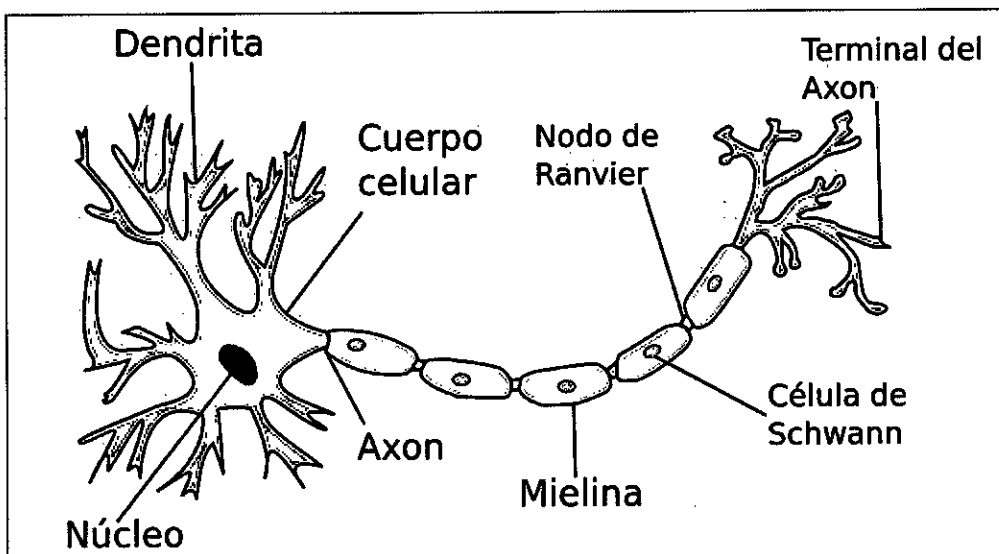
La teoría y el modelado de las redes neuronales artificiales se sustentan en información conocida acerca de la estructura y funcionamiento de los sistemas nerviosos biológicos. De todos los elementos que componen a estos sistemas, la neurona es el bloque básico de construcción y funcionamiento. Aunque en la naturaleza éstas

pueden encontrarse en diversas formas, tamaños y longitudes, su estructura y principio de funcionamiento esencialmente parecen ser siempre los mismos. A continuación, algunas generalidades acerca de su anatomía y fisiología.

c. Estructura de las neuronas

Las neuronas son células vivas que contienen aquellos elementos esenciales que forman parte de todas las células biológicas, pero que además presentan algunas características que las hacen únicas y especiales. Anatómicamente, una neurona consta de un cuerpo celular más o menos esférico, de 5 a 10 micras de diámetro, del que se extienden una rama principal, el axón, y varias ramas más cortas, llamadas dendritas. A su vez, esta rama principal o axón puede contener subramas que con frecuencia se hacen más densas y numerosas cerca de su extremo posterior.

Figura N° 15
Neurona Biológica

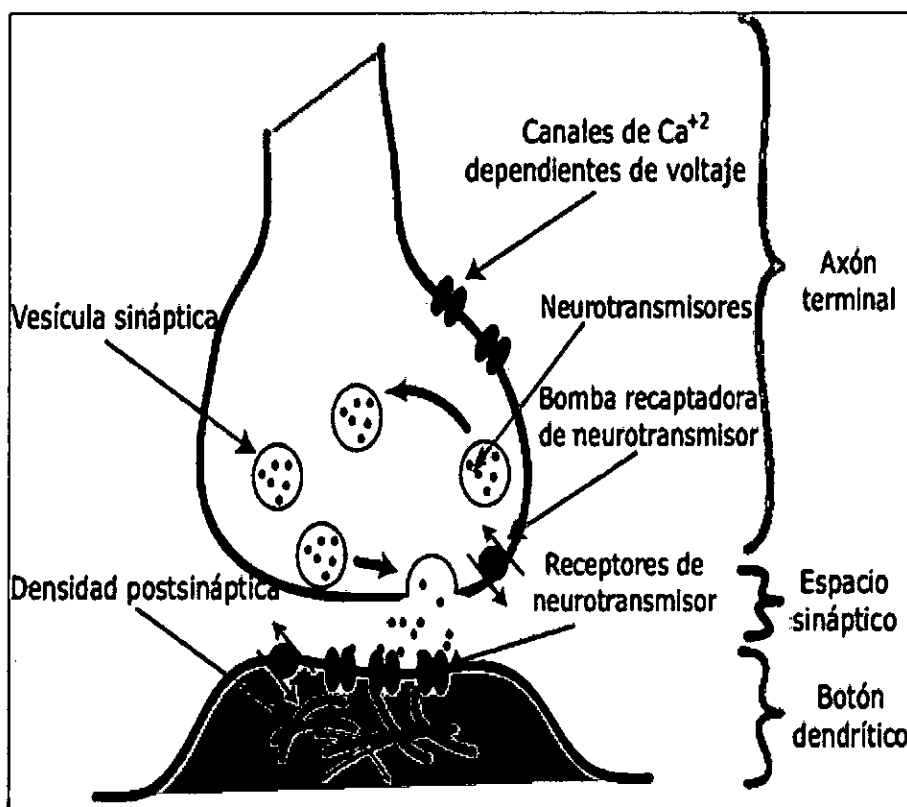


Fuente: propia del autor

Una de las características que diferencian a las neuronas del resto de las células vivas es su expresa capacidad de transmitir impulsos eléctricos. En términos generales, las dendritas y el cuerpo celular reciben señales de entrada; el mismo cuerpo celular las combina e integra y emite señales de salida. El axón transporta esas señales a los terminales axónicos, los cuales se encargan de distribuir la información a un nuevo conjunto de neuronas. Una neurona puede recibir información de miles de otras neuronas y, a su vez envía información a miles de neuronas más. Se estima que en cerebro humano existen conexiones en el orden de magnitud de 10^{15} .

Figura N° 16

Esquema de conexión típica (sinapsis) entre 2 neuronas



Fuente: propia del autor

d. Naturaleza bioeléctrica de las neuronas

Las señales utilizadas en las redes neuronales biológicas son de dos tipos: eléctricas y químicas. La señal generada por la neurona y que es transportada a lo largo del axón es un impulso eléctrico, en tanto que la señal transmitida entre los terminales axónicos de una neurona y las dendritas de las neuronas siguientes es de origen químico. Este último tipo de señal media en el intercambio de información entre neuronas y se realiza a través de los espacios inter-neuronales (50-200 Ångstroms de separación). A este proceso de comunicación entre neuronas se le conoce como transmisión sinóptica, y es llevado a cabo a través de unas moléculas llamadas neurotransmisores, las cuales fluyen de una neurona a otra por este pequeño espacio gracias a receptores específicos. La codificación de la información que se intercambia entre neuronas viene dada por varios factores como el tipo de neurotransmisor, el volumen del mismo, la velocidad de flujo, etc. Estos determinan variaciones particulares que son interpretadas por las neuronas circundantes y que marcan dentro de la red total zonas diferenciales de actividad.


En cuanto a las señales de tipo eléctrico, se sabe que éstas son originadas en los sensores de frontera con el medio (input), conocidos comúnmente como los sentidos. Desde allí se propagan a través de la red hasta el cerebro para desencadenar una respuesta o reacción (output).

La generación de estas señales eléctricas está íntimamente relacionada con la composición de la membrana celular. Existen muchos procesos complejos involucrados en dichas señales, sin embargo, se pueden simplificar para un más fácil entendimiento. Las neuronas, como todas las

células, son capaces de mantener en su interior un líquido cuya composición difiere marcadamente de la composición del líquido exterior. La diferencia más notable se da en relación con la concentración de iones sodio y potasio. Esta diferencia de concentración en ambos iones a cada lado de la membrana produce una diferencia de potencial de aproximadamente 70 milivoltios, negativa en el interior de la célula. Esto es lo se conoce como el potencial de reposo de una célula nerviosa.

Figura N° 17

Propagación del impulso eléctrico a lo largo del axón.



Fuente: propia del autor

La llegada de señales procedentes de otras neuronas a través de las dendritas actúa de una manera acumulativa, bajando ligeramente el valor del potencial de reposo. Dicha variación modifica la permeabilidad de la membrana, de manera que cuando llega a cierto valor crítico se inicia una entrada masiva de iones sodio que cambian la relación de cargas. La inversión del voltaje de la cara interior de la membrana cierra el paso a los iones sodio y a su vez abre el paso a los iones potasio hasta que se reestablece el equilibrio de reposo. La inversión del voltaje, conocida como el potencial de acción, se propaga a lo largo del axón y, a su vez, provoca la emisión de los neurotransmisores en los terminales axónicos. Luego de un pequeño período refractario, puede darse un segundo impulso. El resultado de todo esto es la emisión por parte de la neurona de trenes de impulsos cuya frecuencia varía en función (entre otros factores) de la cantidad de neurotransmisores recibidos.

Existen dos tipos de sinapsis:

- las sinapsis excitatorias, cuyos neurotransmisores provocan disminuciones de potencial en la membrana de la célula postsináptica, facilitando la generación de impulsos a mayor velocidad.
- las sinapsis inhibitorias, cuyos neurotransmisores tienden a estabilizar el potencial de la membrana, reduciendo la emisión de impulsos.

Casi todas las neuronas reciben entradas procedentes de sinapsis excitatorias e inhibitorias. En un instante dado, algunas de ellas estarán activas y otras se hallarán en reposo; la suma de los efectos excitadores e inhibidores determinan si la célula será o no estimulada, es decir, si emitirá o no un tren de impulsos y a qué velocidad.

Con el fin de establecer una analogía entre lo anterior y las redes neuronales artificiales, a continuación, se describen algunos de los aspectos fundamentales de éstas últimas.

e. Definición y características de las redes neuronales artificiales

Las Redes Neuronales Artificiales (RNA), llamadas también sistemas conexionistas, son sistemas de procesamiento de información, cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas. A través de su reciente historia, diferentes autores les han dado diversas definiciones:

"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 conformado por un gran número de elementos simples, elementos de proceso muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas."

"Redes de elementos simples conectados masivamente y en paralelo, con una organización jerárquica, que interactúan con el mundo real en una forma análoga a como lo hacen los sistemas nerviosos biológicos."

"Es un procesador masivamente paralelo que posee una propensión natural de almacenar conocimiento experimental y hacerlo disponible para el uso. Se asemeja al cerebro en dos aspectos:

- El conocimiento es adquirido por la red a través de un proceso de aprendizaje
- Las conexiones entre neuronas conocidas como pesos sinópticos son utilizadas para almacenar el conocimiento."

Más precisamente, otros aspectos que definen y caracterizan una red neuronal son su topología, su mecanismo de aprendizaje, el tipo de asociación realizada entre la información de entrada y de salida, y la manera de representar estas informaciones. Estos se discutirán en las secciones subsiguientes, no obstante, es conveniente apuntar ciertos detalles particulares de las redes neuronales artificiales cuando se les compara con los modelos tradicionales de hacer computación. La arquitectura de procesamiento de la información de los sistemas de RNA se distingue de la arquitectura convencional Von Neumann (que es el fundamento de la mayor parte de los computadores existentes) en una serie de aspectos trascendentales. En primer lugar, el procesamiento de la información de un modelo Von Neumann es secuencial mientras que el procesamiento en un sistema conexionista es paralelo, esto es, muchas unidades de procesamiento pueden estar funcionando simultáneamente.

En segundo lugar, un rasgo fundamental de una arquitectura Von Neumann es el carácter discreto de su memoria, mientras que en redes neuronales, la información no se almacena en compartimentos discretos, sino que se distribuye a través de los pesos que vinculan unas neuronas con otras. Los parámetros que definen el "conocimiento" que una red neuronal posee en un momento dado son sus conexiones y las funciones de activación de sus unidades de procesamiento. En un sistema conexionista las expresiones lingüísticas o simbólicas (reglas explícitas) no existen como tales, sino que son el resultado emergente de la interacción de muchas unidades en un nivel subsimbólico o carente de un conjunto establecido de símbolos interpretables.

Por último, un sistema de RNA no se programa para realizar una determinada tarea a diferencia de una arquitectura Von Neumann, sino que es entrenado para tal efecto.

Considérese un ejemplo típico de aprendizaje o formación de conceptos en la estructura de una RNA. Supóngase que se le presentan a una red dos tipos de objetos, por ejemplo la letra A y la letra E con distintos tamaños y en distintas posiciones. En el aprendizaje de la red neuronal se consigue, tras un número elevado de presentaciones de los diferentes objetos y consiguiente ajuste o modificación de las conexiones del sistema, que la red distinga entre As y Es, sea cual fuere su tamaño y posición en la pantalla. Para ello, podríamos entrenar la red neuronal para que proporcionase como salida el valor 1 cada vez que se presente una A y el valor 0 en caso de que se presente una E. El aprendizaje en una RNA es un proceso de ajuste o modificación de los valores o pesos de las conexiones, hasta que la conducta del sistema acaba por reproducir las propiedades estadísticas de sus entradas.

En el presente ejemplo, podría decirse que la red ha "aprendido" el concepto de letra A y letra E sin poseer reglas concretas para el reconocimiento de dichas figuras, sin poseer un programa explícito de instrucciones para su reconocimiento. Por lo tanto, para entrenar a un sistema conexionista en la realización de una determinada clasificación es necesario realizar dos operaciones. Primero, hay que seleccionar una muestra representativa con respecto a dicha clasificación, de pares de entradas y sus correspondientes salidas. Segundo, es necesario un algoritmo o regla para ajustar los valores modificables de las conexiones entre las unidades en un proceso iterativo de presentación de entradas, observación de salidas y modificación de las conexiones.

Las RNA son entonces un modelo que, bajo altos niveles de simplificación, trata de reproducir algunas características del comportamiento del cerebro. Dicha simplificación induce a determinar cuáles son los elementos relevantes del sistema. Una elección adecuada de componentes y características, aunado a una selección de una estructura conveniente, han permitido a través de los últimos años construir redes neuronales artificiales capaces de realizar tareas particulares.

Como se mencionó anteriormente, el elemento primigenio de una RNA es la neurona. A partir de ella es posible generar representaciones específicas, de tal forma que un conjunto de ellas, bajo un estado particular, puede significar una letra, un número o

cualquier otro objeto. Para lograr esto, cada una de estas neuronas o unidades de proceso consta a su vez de sub-elementos: a su haber conexiones sinópticas de entrada, un estado de activación y una función de salida o de transferencia.

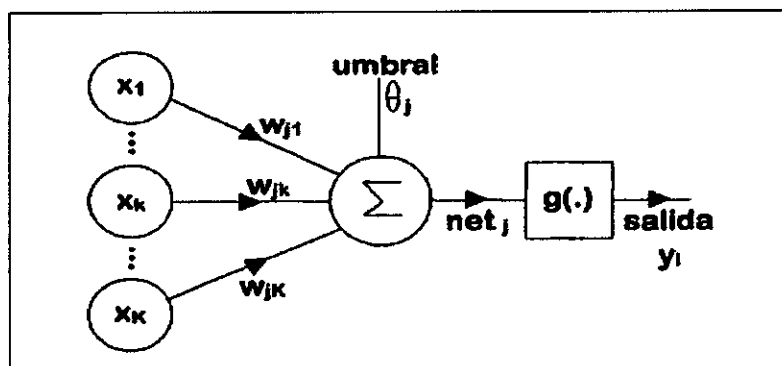
f. La Neurona o Unidad de Proceso

La neurona o unidad de proceso, también conocida como nodo es la unidad de procesamiento fundamental de cualquier red neuronal. En ella se pueden identificar tres elementos principales:

- las entradas o inputs a través de las conexiones sinápticas
- un sumador de las señales de entrada
- una función, $g(\cdot)$, de activación que influye en la salida u output de la neurona

Figura N° 18

Modelo de una neurona artificial donde X son las entradas W representa los pesos e Y la salida



Fuente: propia del autor

El modelo de la neurona expuesto también incluye un umbral (conocido como bias) que participa como otra entrada al sumador. Dicho elemento representa un fenómeno

biológico característico de las neuronas; éstas requieren, para disparar su activación, que el efecto acumulativo de todas las entradas provenientes de las neuronas conectadas supere cierto umbral. En neuronas vivas esto sucede gracias a variaciones eléctricas en los potenciales celulares. En una neurona artificial este umbral viene dado usualmente por una neurona conectada como entrada cuya salida es un valor fijo o constante (por ejemplo 1 o -1).

En términos matemáticos la neurona de la figura anterior puede definirse mediante la siguiente ecuación :

$$net_j = \sum_{k=1}^K W_{jk} X_k \theta_j$$

Donde x_1, x_2, \dots, x_k son las entradas, $w_{j1}, w_{j2}, \dots, w_{jk}$ son los pesos sinápticos que convergen a la neurona j y θ_j es el bias o umbral, el estado global o estado de activación que alcanza una neurona tras la sustitución de valores en la ecuación es luego transmitido a la función de activación $g(\cdot)$ y finalmente a la salida.

g. El estado de activación

Una neurona artificial puede tener diferentes estados de activación; a veces como las neuronas biológicas solamente dos, pero otras veces pueden tomar cualquier valor dentro de un rango definido. La función de activación calcula el estado de actividad de una neurona; transformando la entrada global (menos el umbral) en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1).

Una definición formal para un estado de activación resultante de una función de activación de tipo lineal es el siguiente:

$$f(x) = \left\{ \begin{array}{ll} -1 & x \leq -\frac{1}{a} \\ a * x & -\frac{1}{a} < x < \frac{1}{a} \\ 1 & x \geq \frac{1}{a} \end{array} \right\}$$

$$\text{con } x = g \text{ in}_i - \theta_i \text{ donde } a > 0$$

Donde $g \text{ in}_i$ representa el estado global producto de las entradas y pesos a la neurona y θ_j es el umbral.

El procesamiento que realiza la red se ve entonces como la evolución de un patrón de activación en el conjunto de unidades que lo componen a través de las fases de entrenamiento. Todas las neuronas que componen la red se hallan en cierto estado, y es el estado global de la red misma el que le brinda un estado de conocimiento.

g. Función de salida o transferencia

Entre las unidades de proceso que conforman una red neuronal, existe un conjunto de conexiones que unen a unas con otras. Cada unidad transmite señales a aquellas que están directamente conectadas a su salida. Asociada con cada unidad **U** (hay una función de salida $f_i(a_i(t))$), que transforma el estado actual de activación $a_i(t)$ en una señal de salida $y_i(t)$, es decir:

$$Y_i(t) = f_i(a_i(t))$$

Y el vector que contiene las salidas de todas las neuronas en un instante t es:

$$Y(t) = (f_1(a_1(t)), f_2(a_2(t)), f_3(a_3(t)), \dots, f_N(a_N(t)))$$

En algunos modelos, esta salida es igual al nivel de activación de la unidad, en cuyo caso la función f_i es la función identidad, $f_i(a_i(t)) = a_i(t)$. A menudo, f_i es de tipo sigmoideal, y suele ser la misma para todas las unidades.


Existen cuatro funciones de transferencia típicas que determinan distintos tipos de salidas: Función escalón, función lineal y mixta, función sigmoideal y función Gaussiana.

i. Neuronas con función escalón

La función escalón, conocida también como función umbral se utiliza únicamente cuando las salidas de la red son binarias. La salida de una unidad de proceso se produce solo cuando el estado de activación es mayor o igual a cierto valor umbral.

Figura N° 19

Función de transferencia tipo escalón




Fuente: propia del autor

j. Neuronas con función lineal y mixta

La función lineal o identidad responde a la expresión $f(x) = x$. Esto es equivalente a no aplicar función alguna, o bien conservar el actual estado de activación como la salida. En cambio, en las neuronas con función mixta, si la suma de las señales de entrada es menor que cierto límite inferior, la activación se define entonces como 0 (o -1). Si dicha suma es mayor o igual que el límite superior, entonces la activación es igual a 1. Si la suma de entradas está comprendida entre ambos límites (superior e inferior), entonces la activación se define como una función lineal de la suma de las señales de entrada. Se puede representar las funciones de activación como se muestra en la figura siguiente:

Figura N° 20

Función de transferencia tipo mixto



Fuente: propia del autor


k. Neuronas con función continua (sigmoidea)

Cualquier función definida simplemente en un intervalo de posibles valores de entrada, con un incremento monótonico y que tenga ambos límites superior e inferior (por ejemplo la función sigmoidea o la arco tangente), podrá realizar la función de activación o de transferencia de manera satisfactoria.

Con la función sigmoidea, para la mayoría de los valores de entrada, se retorna un valor que es cercano a una de las asíntotas. Esto hace que en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o bien baja del sigmoideo. De hecho, cuando la pendiente es elevada, esta función tiende a la función escalón. Sin embargo, la importancia de la función sigmoidea es que su derivada es siempre positiva y cercana a cero para los valores grandes positivos o negativos; además, la función identidad toma su valor máximo cuando X es 0. Esto a su vez posibilita que se puedan utilizar reglas de aprendizaje definidas para las funciones escalón, con la ventaja de que, para la sigmoidea, la derivada está definida en todo el intervalo. La función escalón no puede

definir la derivada en el punto de transición, lo cual no ayuda a los métodos de aprendizaje en los cuales se utilizan derivadas.

Figura N° 21
Función de activación de tipo sigmoideal



Fuente: propia del autor

2.2.16 Conexiones entre neuronas o pesos

Cada conexión entre las neuronas de una RIMA tiene asociado un peso, y en conjunto hacen que la red alcance algún grado de conocimiento. Considérese y_1 como el valor de salida de una neurona / en un instante dado. Una neurona recibe un conjunto de señales que le brindan información del estado de activación de todas las neuronas con las cuales se encuentra conectada. Cada conexión (sinapsis) entre la neurona i y la neurona j está ponderada por un peso iV_j , Normalmente, como simplificación, se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona (potencial post sinóptico) net_j es la suma del producto de cada señal individual por el valor de la sinapsis que conecta ambas neuronas:

$$\text{net}_j = \sum W_{ji} \cdot y_i$$

Esta regla muestra como se combinan los valores de entrada a la unidad con los pesos de las conexiones que llegan a esa unidad y es conocida como regla de propagación.

Suele utilizarse una matriz W con todos los pesos W_{ji} que refleja la influencia que ejerce la neurona i sobre la neurona j . W es un conjunto de valores positivos, negativos o nulos. Si w , es positivo, indica que la interacción entre las neuronas i y j es excitatoria, es decir, siempre que la neurona i está activada, la neurona j recibirá una señal de i que tenderá a activarla. Si W_{ji} es negativo, la sinapsis será inhibitoria. En este caso, si i está activada, enviará una señal a j que tenderá a desactivar a ésta. Finalmente, si $W_{ji} = 0$, se supone que no hay conexión entre ambas.

A continuación, se describen algunas de las arquitecturas de redes neuronales artificiales más conocidas, haciéndose énfasis en aquellas que serán utilizadas en la investigación.

2.2.17 Tipos de arquitectura en las redes neuronales artificiales

Existen diversos tipos de arquitecturas en las redes neuronales artificiales, que en principio, están determinadas por la manera en la que sus neuronas se disponen así como por la relación que se establece entre ellas. El número de capas, la cantidad de neuronas por capa, el grado y tipo de conexiones entre neuronas y entre capas constituyen las principales características topológicas de una RNA.

Según el número de capas, las redes neuronales artificiales se clasifican en dos tipos: de una capa y de múltiples capas. En las redes de una capa se establecen conexiones laterales, cruzadas o auto recurrentes entre las neuronas de la red. Se utilizan en tareas relacionadas con lo que se conoce como auto asociación; por ejemplo, para generar informaciones de entrada que se presentan a la red ya sea incompletas o distorsionadas. Dos ejemplos son la red de HOPFIELD y la BRAIN-STATE-1N-A-BOX.

Las redes multicapa por su parte son aquellas que disponen de conjuntos de neuronas agrupadas en varios niveles o capas. Una forma de distinguir la capa a la que pertenece la neurona, consiste en fijarse en el origen de las señales que recibe a la entrada y el

destino de la señal de salida. Normalmente, todas las neuronas de una capa reciben las señales de entrada de otra capa anterior, más cercanas a la entrada de la red, y envían la salida a una capa posterior, más cercana a la salida de la red. Según el tipo de conexión, se distinguen las redes feedforward, y las redes feedforward/ feedback. En las primeras, todas las señales se propagan hacia adelante a través de las capas de la red. No existen conexiones hacia atrás, y normalmente tampoco auto- recurrentes ni laterales, excepto en algunos modelos propuestos por Kohonen. Las redes feedforward más conocidas son: PERCEPTRÓN, ADALINE, MADALINE, LINEAR ADAPTIVE MEMORY, BACKPROPAGATION. En cuanto a las redes feedforward / feedback, se da un flujo de información tanto hacia adelante como hacia atrás, esto gracias a conexiones independientes. En general, excepto en el caso particular de las redes COGNITRON y NEOCOGNITRON, suelen ser de dos capas, existiendo por lo tanto dos conjuntos de pesos, que no necesariamente coinciden uno con el otro.


Seguidamente se anotan las principales características de los tres tipos de redes utilizados en la investigación; una del tipo Perceptrón Multicapa (PMC), una red auto recurrente de Elman y una red auto organizativa de Kohonen.

a. Perceptrón Multicapa (PMC)

Varias unidades de proceso pueden combinarse para formar una capa de neuronas (perceptrón mono capa) y varias capas pueden a su vez combinarse para formar un Perceptrón Multicapa (PMC). En el caso de la red mono capa, que es el más simple posible en este tipo de redes, la información fluye desde las entradas hasta una sola capa de salida. Cuando este modelo se extiende a una red con por lo menos una capa más, se habla ya de un PMC. Las entradas se denominan capa 0 porque no realizan ningún cálculo, su cometido es presentar los patrones a la red. La siguiente capa (capa 1) es una capa oculta, la cual recibe los datos provenientes de la capa 0 y tras algún procesamiento pasa información a la capa siguiente, que puede ser otra capa oculta o bien la capa de salida en este caso. La figura 10 muestra una red de este tipo, con alimentación hacia delante, con una capa 0 de K neuronas, una capa oculta de J neuronas y una capa de salida de I neuronas.

Figura N° 22

Arquitectura típica de una red PMC con una capa oculta y alimentación hacia adelante



Fuente: propia del autor


b. Red recurrente de Elman

Inicialmente propuesta por Jordán en 1988 y posteriormente modificada por Elman en 1990 la arquitectura de esta red es similar a una red PMC con una capa oculta. Está conformada por una capa de entrada por donde se presentan los datos, una capa oculta en donde se realiza la representación interna de la información y una capa donde se producen las salidas (capa de salida). Adicionalmente existe otra capa denominada capa de contexto, la cual recibe información directamente de la capa oculta y transmite su salida a la misma capa oculta. Esta capa de contexto produce lo que se conoce como un retardo o delay, el cual permite a la red almacenar información del estado anterior inmediato de las conexiones cuando se encuentra en la fase de aprendizaje. Con esto, una red Elman es capaz no solo de aprender a reconocer las particularidades contenidas en los patrones de entrada, sino también a construir una representación de las propiedades temporales o espaciales presentes en dichos patrones [Elman90]. Un requisito para este tipo de red es que se debe asignar un número mayor de neuronas en la capa oculta que el que requiere por ejemplo una red PMC. La justificación a esto

viene dada por el aumento en complejidad de la función que la red aproxima internamente para lograr el mapeo temporal o espacial antes mencionado.

Figura N° 23

Arquitectura de una red recurrente de Elman con una capa oculta. Se aprecia la conexión recurrente en la capa oculta y la capa contexto



Fuente: propia del autor

c. Red auto-organizativa de Kohonen

Existen evidencias que demuestran cierto nivel de organización espacial de grupos de neuronas en el cerebro humano, permitiendo una representación ordenada de la información adquirida a través de los órganos sensoriales. Esta organización parece darse principalmente en la corteza, en la forma de mapas bidimensionales. Dos ejemplos que se han estudiado son los mapas del campo visual encontrados en la parte de la corteza encargada de este sentido y los mapas auditivos encontrados en la parte que procesa los sonidos.


Dichas evidencias impulsaron a T. Kohonen a proponer en 1982 un modelo de red neuronal artificial capaz de formar mapas de características en una manera similar a como se ha observado que ocurre en el cerebro. Este modelo cuenta con dos variantes;

LVQ (Learning Vector Quantization) y SOM (Self Organizing Map) o Mapa Auto-organizativo de Kohonen (MAK). Ambas parten del principio de la formación de mapas topológicos para establecer características comunes entre los datos de entrada a la red.

En términos generales, la LVQ es una red de dos capas con W neuronas de entrada, en donde cada una de éstas se conecta con M neuronas de salida a través de conexiones hacia delante (feedforward). Además, puede decirse que entre las neuronas de la capa de salida existen conexiones laterales de inhibición, modeladas a través de una función de proximidad o vecindad,

Figura N° 24

Arquitectura de una red auto organizativa de Kohonen LVQ. A las entradas le sigue la capa auto-organizativa de neuronas que aprenden por competencia.



Fuente: propia del autor

El MAK por su parte consiste en una capa de neuronas distribuidas en un espacio n -dimensional que generalmente tiene la forma de un hipercubo y al cual se le puede imaginar como una "rejilla" en donde se ubican las neuronas. Esta rejilla sirve para establecer una relación de distribución y de vecindad entre aquellas y se dice entonces que en una rejilla n -dimensional cada neurona- excepto las que se encuentran en los bordes tiene $2 * n$ vecinos.

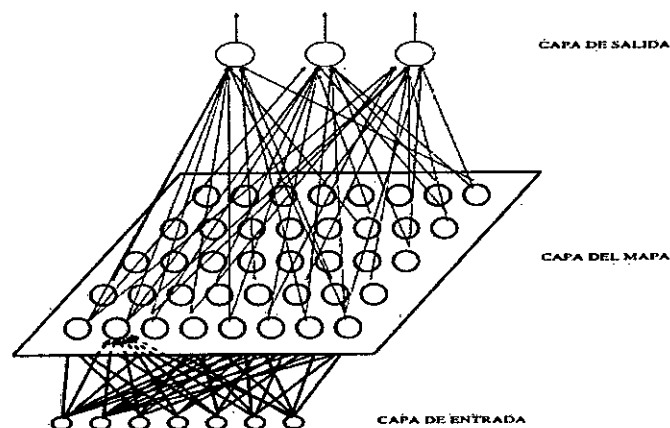
El MAK define una red elástica de puntos (vectores prototipo) que se ajustan al espacio de señales de entradas para aproximar la función de densidad de probabilidad de la variable vectorial de entrada. El MAK se usa extensivamente en minería de datos, representación de datos multidimensionales en dos dimensiones, categorización de datos (clustering) y análisis de relaciones entre variables.

La distancia entre éstas neuronas vecinas se suele medir a través de la distancia Euclidiana, que no es más que la distancia lineal que existe entre una neurona A y una neurona B. Cada neurona tiene además un vector prototipo, que es un vector de pesos, tantos como dimensiones.

La idea detrás consiste en establecer una adecuada correspondencia entre los datos de entrada y el espacio n-dimensional de salidas. Es común que estos mapas de salida sean de dos dimensiones, lo que facilita su visualización e interpretación. Los MAK aprenden a través de entrenamiento no supervisado y por lo que se conoce como aprendizaje competitivo.

Figura N° 25

Arquitectura de una red auto organizativa de Kohonen MAK. Las neuronas de entrada se encuentran conectadas a un mapa bidimensional de M neuronas



Fuente: propia del autor

Existen muchos problemas del mundo real donde existe un conjunto de datos de entrenamiento, pero no se conocen las salidas deseadas. En estos casos la información relevante debe de ser localizada en los propios patrones de entrada, por lo que se dice debe existir algún nivel de redundancia en la información. Algunas áreas concretas de aplicación de los MAK son:

- Conglomerados o clustering: Los datos de entrada pueden ser agrupados en "clusters" y el sistema al procesar los datos debe de encontrar los centros de esos clusters.
- Cuantización Vectorial: Esto ocurre cuando por ejemplo un espacio continuo tiene que hacerse discreto. La entrada al sistema son vectores n-dimensionales y la salida es una representación discreta del espacio de entradas.
- Reducción de Dimensionalidad: Los datos de entrada deben de ser agrupados en un sub-espacio con una dimensionalidad más baja que la dimensionalidad de los datos.
- Extracción de Características: El sistema tiene que extraer características de los datos de entrada (supone casi siempre una reducción de la dimensionalidad)

La arquitectura de una red neuronal artificial determina en buena parte la forma en que esta puede ser entrenada para aprender a partir de la información de entrada. Seguidamente se introducen algunas nociones básicas sobre este proceso, incluyendo aspectos específicos para las arquitecturas implementadas en el trabajo.

d. Mecanismo de aprendizaje

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 proceso de entrenamiento se reducen a la destrucción, modificación y creación de conexiones entre las neuronas. En los sistemas biológicos existe una continua creación y destrucción de conexiones. 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 forma, una conexión se destruye cuando su peso pasa a ser cero.

Un aspecto importante respecto al aprendizaje de las RIMA 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.

Estos criterios determinan las reglas de aprendizaje de la red. A grandes rasgos, se suelen considerar dos tipos de reglas: las que corresponden a lo que se conoce como aprendizaje supervisado, y las que corresponden al aprendizaje no supervisado. La diferencia fundamental entre ambos tipos estriba en la existencia o no de un agente externo (supervisor) que supervisa el proceso de aprendizaje de la red.

En el aprendizaje supervisado este agente externo comprueba la salida de la red y en caso de que ésta no coincida con la deseada, procederá a modificar los pesos sinópticos, con el fin de conseguir que la salida se aproxime a la deseada. Existen tres estilos de llevar a cabo este tipo de aprendizaje:

- aprendizaje por corrección de error, en donde los pesos se ajustan en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red, o dicho de otra forma, en función del error observado en cada ciclo del entrenamiento,
- aprendizaje por refuerzo, el cual se basa en la idea de no indicar durante el entrenamiento el valor deseado de salida sino más bien aplicar una señal de refuerzo si la salida obtenida se ajusta a la deseada (éxito = +1 o fracaso = -1)
- aprendizaje estocástico, en donde el principio es realizar cambios aleatorios en los valores de los pesos sinópticos de la red y evaluar su efecto a partir del objetivo deseado y de las distribuciones de probabilidad asociadas.

En el aprendizaje no supervisado, la red no recibe ninguna información por parte del entorno que le indique si la salida generada es o no correcta, por lo que se pueden dar varias posibilidades en cuanto a la interpretación de la salida de estas redes. En

algunos casos, la salida representa el grado de familiaridad o similitud entre la información que se le está presentando en la entrada y las informaciones que se le han mostrado en el pasado. En otro caso podría realizar una codificación de los datos de entrada, generando a la salida una versión codificada de la entrada, con menos bits, pero manteniendo la información relevante de los datos. Algunas redes con aprendizaje no supervisado realizan también lo que se conoce como un mapeo de características, obteniéndose en las neuronas de salida una disposición geométrica que representa un mapa topográfico de las características de los datos de entrada, de tal forma que si se presentan a la red informaciones similares, siempre sean afectadas neuronas de salidas próximas entre sí, en la misma zona del mapa.

Dos tipos de aprendizaje no supervisado son:

- aprendizaje Hebbiano, el cual consiste en modificar los pesos de las conexiones de acuerdo a un factor de correlación entre dos neuronas conectadas entre sí. Cuando ambos nodos están activos (positivos), se produce un reforzamiento de la conexión. Por el contrario, cuando uno se encuentra activo y el otro pasivo (negativo), se produce un debilitamiento de la conexión.
- aprendizaje competitivo / cooperativo, en donde las neuronas compiten (y cooperan) unas con otras con el fin de llevar a cabo una tarea asignada. Con este tipo de aprendizaje se pretende que cuando se presente a la red cierta información de entrada, solo una de las neuronas de salida se active (alcance su valor de respuesta máximo).

Por tanto, las neuronas compiten por activarse, quedando finalmente una, o una por grupo, como neurona vencedora.

Otro criterio que puede utilizarse para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual, o bien si el aprendizaje supone la desconexión de la red, es decir su inhabilitación hasta que el proceso termine.

En el primer caso, se trata de un aprendizaje online (en línea), mientras que el segundo se conoce como aprendizaje of

line (fuera de línea), Cuando el aprendizaje es fuera de línea, 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 prueba que serán utilizados en la correspondiente fase de funcionamiento.

Considerando las tres arquitecturas seleccionadas en la presente investigación en introducidas en los apartados anteriores, se describen a continuación los algoritmos de entrenamiento o aprendizaje utilizados por cada una de ellas.

e. Aprendizaje de las redes PMC

Las redes tipo PMC utilizan aprendizaje supervisado y el algoritmo más extendido para entrenar estas redes es el de retropropagación (*back propagation*). Este requiere de una red neuronal típica PMC, con conexiones hacia delante y sin conexiones laterales.

Partiendo de una red PMC con una capa oculta, con una colección de patrones de entrada $x(PT)$ y blancos o meta $d(PT)$ a ser mapeados, el algoritmo puede describirse como sigue:

- Se inicializan los pesos de toda la estructura neuronal en valores aleatorios pequeños
- Se presenta el patrón de entrada $x(p)$ de la colección de patrones de entrenamiento
- Se calcula las salidas en las neuronas de la capa oculta y de la capa de salida a través de las respectivas ecuaciones:

$$y^1_j(p) = g(\text{net}^1_j(p)) = g \left[\sum_{k=0}^K w^1_{jk} x_k(p) \right] \quad 1 \leq j \leq J$$

$$y^2_l(p) = g(\text{net}^2_l(p)) = g \left[\sum_{j=0}^J w^2_{lj} y^1_j(p) \right] \quad 1 \leq l \leq L$$

a. Se verifica si $y^2_i(p) = d_i(p)$ (target) para $1 \leq i \leq I$. Esto conlleva a dos casos posibles:

- Si se cumple la igualdad, ir al paso g
- Si no se cumple la igualdad, continuar con el paso e

b. Se calculan los respectivos términos de error para los nodos en las capas de salida y oculta (es este orden), para retro-propagar el error a través de la red. Esto se realiza a través de las ecuaciones:

$$y^1_j(p) = g(\text{net}^1_j(p)) = g \left[\sum_{k=0}^K w^1_{jk} x_k(p) \right] \quad 1 \leq j \leq J$$

$$y^2_i(p) = g(\text{net}^2_i(p)) = g \left[\sum_{j=0}^J w^2_{ij} y^1_j(p) \right] \quad 1 \leq i \leq I$$

c. Una vez calculadas las salidas y los términos de error, se actualizan los pesos de acuerdo con:

$$\Delta w^2_{ij} = \eta \delta^2_i(p) y^1_j(p) \quad 1 \leq i \leq I, 0 \leq j \leq J$$

$$\Delta w^1_{jk} = \eta \delta^1_j(p) x_k(p) \quad 1 \leq j \leq J, 0 \leq k \leq K$$

d. Ahora, ante los dos posibles casos:

- $p \neq \text{PT}$, ir al paso b y presentar el siguiente patrón de entrada
- $p = \text{PT}$, y un criterio de convergencia ha sido satisfecho (por ejemplo

que la suma de errores al cuadrado sea menor que un valor predefinido), el entrenamiento se da por finalizado. Si este criterio no se ha cumplido, ir al paso b y presentar el primer patrón de entrenamiento.

Existen muchas variantes del algoritmo de retropropagación. La más común realiza la actualización de los pesos en la dirección en la cual la función de desempeño (encargada del error medio cuadrático) decrece más rápidamente, esto es, hacia la dirección negativa del gradiente. Es por eso que se utiliza el término gradiente descendente, pues en realidad el entrenamiento busca minimizar dicha función por pequeños pasos a través de un descenso paulatino.

Además se puede contar con la participación de otro parámetro denominado momentum, el cual establece el cambio en los pesos como la suma de una fracción del último valor de cambio de pesos y el nuevo cambio sugerido por la regla de retropropagación. La magnitud del efecto que el último cambio en el peso puede ejercer es mediada por la constante del momentum, la cual puede ser un valor entre 0 y 1.

f Aprendizaje de las redes Elman

En términos generales, las redes Elman pueden aprender a través del algoritmo de retropropagación. Aduciendo a la particularidad de este tipo de redes, la capa de contexto es tratada como otra capa oculta, en la que simplemente queda almacenada información del estado anterior interno de la red. La capa oculta tiene la tarea de realizar el mapeo no solo de su información con la información de la capa de salida, sino también con la información contenida en esta capa de contexto [Dietrich03]. Esto se traduce en un mayor número de cálculos durante la etapa de entrenamiento, pero básicamente las funciones tanto de error como de salidas y la forma de actualización de pesos son homologas a las utilizadas por el mecanismo de retropropagación.

g. Aprendizaje de las redes de Kohoer

Estas redes utilizan aprendizaje no supervisado de tipo competitivo. En su entrenamiento se presenta a la red un conjunto de vectores de entrada y la red busca establecer categorías o grupos en función de la semejanza de la información contenida en dichos vectores. El número de posibles categorías viene determinada por el número de neuronas definidas para la capa de salida.

El algoritmo de aprendizaje utilizado para asignar los valores a los pesos sinópticos entre las N neuronas de entrada y las M neuronas de salida puede resumirse así:

- Se inicial los pesos (w_{ji}) con valores aleatorios pequeños y fijar la zona inicial de vecindad entre las neuronas de la capa de salida.
- Se presenta a la red los patrones de entrada de la forma $E_k = (e_1^{(k)}, \dots, e_N^{(k)})$.
- Para cada patrón de entrada se determina la neurona vencedora (aquella cuyo vector de pesos sinópticos sea más parecido a dicho patrón de entrada). Esto se efectúa calculando las distancias o diferencias entre ambos vectores. La distancia Euclidiana suele ser el método más utilizado:

$$d_j = \sum_{i=1}^N (e_i^{(k)} - w_{ji}) \quad 1 \leq j \leq M$$

Siendo $e_i^{(k)}$ el componente i-ésimo del vector k-ésimo de entrada, w_{ji} el peso de la conexión entre la neurona i de la capa de entrada y la neurona j de la capa de salida.

- Una vez determinada la neurona vencedora se actualizan los pesos de las conexiones entre las entradas y la neurona vencedora, asociando la información de entrada con cierta zona de la capa de salida. Esto se hace con lo que se conoce como la regla de aprendizaje de Kohonen (learnkr o Kohonen Learning Rule) y que se realiza a través de:

$$w_{ji}(t+1) = w_{ji}(t) + \alpha(t)[e_i^{(k)} - w_{j+1}(t)] \quad \text{para } j \in \text{Zona}_j(t)$$

donde $\text{Zona}_j(t)$ es la zona de vecindad alrededor de la neurona vencedora j. Vale decir que el tamaño de esta zona se puede reducir en cada iteración del proceso de ajuste de pesos, con lo que el conjunto de neuronas que pueden considerarse vecinas cada vez es menor.

El término $\alpha(t)$ es un parámetro de ganancia o coeficiente de aprendizaje, con valor entre 0 y 1, el cual decrece con el número de iteraciones (t).

- Repetir el proceso presentando nuevamente todo el juego de patrones de entrada hasta cumplir una condición de parada (por ejemplo, realizar el ciclo 500 veces, $t \leq 500$).

2.2.18 El Espectrograma aplicado a la Acústica

El sonido obtenido al detectar una fuga no visible en la red de agua potable esta compuesta de 3 propiedades físicas fundamentales que la describen: amplitud, longitud de onda y frecuencia.

La amplitud es el valor máximo del movimiento de una onda y refleja la intensidad y refleja la intensidad con que la perturbación se ha producido. La distancia entre 2 compresiones o entre 2 expansiones se denomina longitud de onda. La frecuencia se define como el número de cambios (de una compresión a otra , por ejemplo que ocurren en un lugar dado en el transcurso de 1 segundo , la frecuencia y el periodo se relacionan de manera inversa :

$$\text{Frecuencia} = 1 / \text{Periodo o bien: } f = 1/T$$

Cuando una onda tiene lugar en un medio liquido o gaseosos se denomina onda acústica y cuando resulta audible se llama onda sonora, las ondas acústicas bajo condiciones normales (temperatura de 25 °C) viajan en el aire a una velocidad de 344 metros por segundo . En otros medios el sonido viaja a diferentes velocidades.

Tabla N° 2

MEDIO	VELOCIDAD EN m/s
Oxigeno	317
Hidrógeno	1270
Agua Dulce	1435
Acero	5000

Fuente: propia del autor

Los sonidos por su naturaleza son periódicos (caso de los instrumentos musicales) y la gran mayoría de sonidos naturales son aperiódicos, esto es las sucesivas perturbaciones no se producen a intervalos regulares y no mantienen constante la forma de la onda estos es lo que técnicamente se denomina ruido.

El concepto de espectro es de importancia capital en acústica. Cuando se introdujo el concepto de frecuencia, se dijo que las ondas periódicas tienen asociada una frecuencia. Sin embargo, esto es sólo parte de la verdad, ya que por lo general dichas ondas contienen varias frecuencias a la vez. Esto lo explica un notable teorema matemático denominado Teorema de Fourier (en honor a su descubridor, el matemático francés Joseph Baptiste Fourier), que afirma que cualquier forma de onda periódica puede descomponerse en una serie de ondas de una forma particular denominada onda senoidal (o senoide, o senoide), cada una de las cuales tiene una frecuencia que es múltiplo de la frecuencia de la onda original (frecuencia fundamental). Así, cuando escuchamos un sonido de 100 Hz, realmente estamos escuchando ondas senoidales de frecuencias 100 Hz, 200 Hz, 300 Hz, 400 Hz, 500 Hz, etc. Estas ondas senoidales se denominan armónicos del sonido original, y en muchos instrumentos musicales (como la guitarra) y ciertos animales (como las aves) son claramente audibles.

La descripción de las ondas senoidales que componen un sonido dado se denomina espectro del sonido. El espectro es importante debido a varias razones. Primero porque permite una descripción de las ondas sonoras que está íntimamente vinculada con el efecto de diferentes dispositivos y modificadores físicos del sonido. En otras palabras, si se conoce el espectro de un sonido dado, es posible determinar cómo se verá afectado por las propiedades absorbentes de un material, por ejemplo. No podría decirse lo mismo en el caso en que se conozca sólo la forma de onda.

En segundo lugar, el espectro es importante porque la percepción auditiva del sonido es de naturaleza predominantemente espectral. En efecto, antes de llevar a cabo ningún otro procesamiento de la señal acústica, el oído descompone el sonido recibido en sus componentes frecuenciales, es decir en las ondas senoidales que, según el teorema de Fourier, conforman ese sonido. Por ese motivo, con algo de práctica es posible por ejemplo reconocer las notas de un acorde. El teorema de Fourier en su forma trigonométrica se puede expresar como sigue:

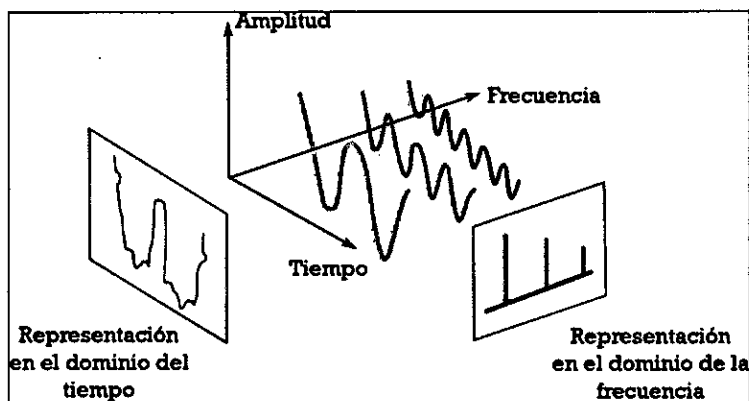
$$f(x) = a_0 \sum_{k=1}^{\infty} (a_k \cos k w_0 x + b_k \sin k w_0 x)$$

Donde x representa el periodo de la señal, a y b son coeficientes de amplitud, w la fase o ángulo.

Toda señal acústica puede ser descrita grafica o matemáticamente de 2 maneras; una expresada como la amplitud en función del tiempo (*time – domain*) y la otra expresada como la amplitud en función de la frecuencia (*frequency – domain*).

Figura N° 26

Descripción Grafica y Matemática de una señal Acústica



Fuente: Propia del autor

Los dispositivos convencionales de grabación registran las señales almacenando los cambios de presión percibidos durante un lapso continuo de tiempo. Al graficar esta información lo que se produce es una representación en el dominio del tiempo. Sin embargo, para muchos tipos de análisis esta representación no es suficiente.

El proceso de pasar de la representación desde el dominio del tiempo hacia el dominio de la frecuencia es denominado análisis de espectro. Así, es posible observar los diferentes componentes frecuenciales que contribuyen a la señal. La función que permite este cambio se conoce como la transformada de Fourier (la figura N° muestra un ejemplo de la transformación).


Hoy en día un gran número de aplicaciones para el tratamiento de sonido e imagen utilizan una versión de esta transformación denominada **Discrete Fourier Transform** (Transformada Discreta de Fourier). En sonidos, se devuelve una secuencia de valores que representan las amplitudes de una secuencia de componentes frecuenciales

discretos, y que son la base para la construcción de representaciones visuales que facilitan posteriores análisis. Una de estas representaciones es el espectrograma, del cual se habla a continuación.

Antes de 1950 la acústica se basó enteramente en el análisis a oído. Con el advenimiento del espectrograma fue posible analizar de una manera más objetiva el sonido. El espectrograma es una representación del tipo tiempo - frecuencia, y muestra el cambio del espectro de frecuencias a través del tiempo. Es una de las representaciones más utilizadas en la investigación acústica, pues permite observar aquellos elementos que componen un sonido en una forma intuitiva y natural, y permite realizar ciertos tipos de análisis que son de interés para determinar diferencias sutiles entre sonidos aparentemente iguales.

Figura N° 27

Espectrograma de una muestra de audio



Fuente: Propia del autor

2.3 Definición de Términos

- **RNA** = Redes neuronales Artificiales
- **Geófono** = Equipo electrónico utilizado para la detección de fugas, consta de un amplificador y un micrófono del tipo de contacto, con este equipo se detectan las fugas no visibles de agua potable en las tuberías guiándose por el sonido que estas emiten.
- **Correlador**= Equipo que permite la localización exacta de una fuga de agua.
- **Correlación** = Procedimiento utilizado para comparar 2 señales de audio.
- **Espectrograma** = Es la representación gráfica del espectro de frecuencias de la emisión sonora.

CAPÍTULO - 3

3 VARIABLES E HIPÓTESIS

El presente problema objeto de investigación, posibilitarán la explicación, demostración y probación de la hipótesis formulada, para ello, se han identificado dos variables independientes y una variable dependiente, las que son definidas:

3.1 Definición de las variables

3.1.1 Algoritmo con Redes Neuronales Artificiales en MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.

Indicador: Sonidos capturados por el Geófono.

Es la variable independiente (X) el algoritmo (programa) el cual permita de manera eficaz y eficiente la detección de las fugas, basado en los sonidos capturados por el geófono.

3.1.2 La detección de fugas utilizando redes neuronales artificiales repercutirá en un mejor rendimiento del servicio reduciendo los porcentajes de agua no facturada

Es la variable dependiente (Y) establece que la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima usando redes neuronales artificiales reducirá los porcentajes de agua no facturada por la empresa prestadora del servicio.

3.1.3 La contaminación sonora (ruido y el tipo de suelo donde se encuentra la tubería influyen en la detección de fugas

Es la variable interviniente (Z) la cual nos indica que factores afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima.

3.2 Operacionalización de variables

3.2.1 VARIABLE: X (independiente) Algoritmo con Redes Neuronales Artificiales en MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.

Indicador: Sonidos capturados por el Geófono.

3.2.2 VARIABLE: Y (dependiente)

La detección de fugas utilizando redes neuronales artificiales repercutirá en un mejor rendimiento del servicio reduciendo los porcentajes de agua no facturada.

3.2.3 VARIABLE: Z (interviniente)

La contaminación sonora (ruido y el tipo de suelo donde se encuentra la tubería influyen en la detección de fugas.

3.3 Hipótesis general e hipótesis específicas

3.3.1 Hipótesis general

Modelamiento inteligente haciendo uso de las redes Neuronales Artificiales con Matlab, el cual permita de manera eficaz y eficiente, la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.

3.3.2 Hipótesis específica 1:

Modelando con Redes Neuronales en MATLAB para el reconocimiento y detección de fugas de agua potable en la ciudad de Lima.

3.3.2 Hipótesis específica 2:

Determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima

CAPITULO - 4

4. METODOLOGÍA

4.1 Tipo de investigación

De acuerdo al problema objeto de estudio, esta investigación es predominantemente estadística, experimental tecnológica, aplicada o I+D, científica y transversal, las que se justifican:

- **Experimental tecnológica.** Porque se instaurará el equipo localizador inteligente para la detección de fugas no visibles de agua potable, de igual manera, es tecnológica porque para su instauración se utilizarán equipos electrónicos.
- **Aplicada (I+D).** Con la Investigación más Desarrollo, se tiene como objetivo, evidenciar que el sistema utilizado actualmente para la detección de fugas no visibles es causal de errores y que puede ser mejorado y/o optimizado con beneficio para la empresa prestadora del servicio y por ende para los consumidores.
- **Científica.** Porque se aplicarán conocimientos matemáticos de Redes Neuronales con el software *MATLAB* para su modelamiento.

- **Transversal.** Toma este nombre porque el inicio y término de esta investigación es menor a un año o doce meses, que en este caso corresponde desde el mes de enero 2017 hasta su culminación, correspondiente a diciembre 2017.

4.2 Diseño de la investigación

4.2.1 Modelando con Redes Neuronales en MATLAB para el reconocimiento y detección de fugas no visibles de agua potable en la ciudad de Lima.

Las fugas en las redes de agua potable de la ciudad de Lima es un problema que se viene presentando desde hace varios años, este problema tiene como factores que lo originan los siguientes:

- Falta de una política de prevención la cual permita el reemplazo periódico de la red de tuberías cuando se cumplan su ciclo de vida ya que muchas de estas son del tipo de Hierro Fundido Dúctil (HD) las cuales se deberían reemplazar por las modernas de Polietileno de Alta Densidad (HDPE).
- El ente encargado de dicha labor no cuenta con los recursos suficientes para realizar labores de reemplazo y reparación de las redes de agua potable en la medida que se requiere.
- Lima ha crecido de forma desordenada y sin supervisión en las últimas décadas dando lugar a que se instalen tuberías en lugares donde por lo endeble del terreno (caso de los rellenos sanitarios) se produzcan frecuentes problemas de roturas y/o fugas de agua en dichas redes.

a. Justificación del uso de las redes neuronales para la detección de fugas no visibles en las redes de agua potable

La detección de fugas no visibles en las redes de agua potable específicamente de la ciudad de Lima requiere superar algunos inconvenientes del operario humano frente a ventajas de aplicar un sistema de reconocimiento de los sonidos utilizando redes neuronales con MATLAB.

b. Opciones de mejora mediante redes neuronales

Un sistema de reconocimiento del sonido basado en algoritmos de redes neuronales es adecuado para el manejo de gran cantidad de información en este caso muestreos de sonidos y su consiguiente interpretación de forma rápida y precisa.

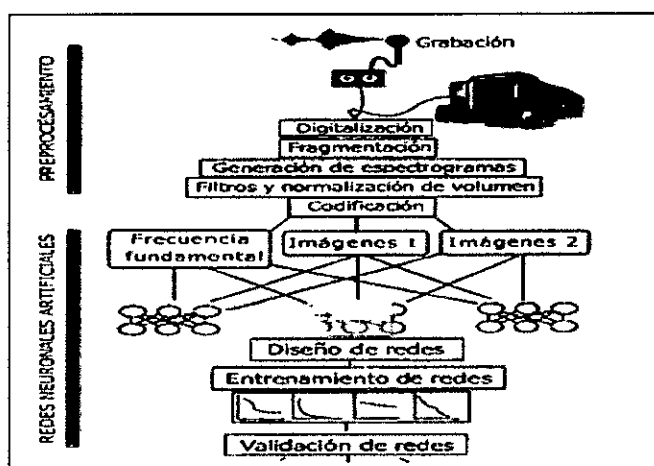
- c. El equipo localizador inteligente será instaurado para que se reduzcan los porcentajes de agua no facturada por la empresa prestadora del servicio.
- d. Determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima.

4.2.2 Redes Neuronales

Primeramente, se presenta un diagrama que resume los diferentes pasos realizados durante el trabajo y posteriormente se relata con más detalle cada uno de ellos, como el origen de los datos, las diversas transformaciones realizadas, los métodos de codificación y las redes neuronales artificiales utilizadas.

Figura N° 28

Diagrama resumen de los pasos metodológicos seguidos a través de la investigación



Fuente: Propia del autor

A partir de grabaciones se digitalizaron y fragmentaron los sonidos de las fugas de agua propiamente dichas. Posteriormente se generó un espectrograma por cada fragmento y se aplicaron filtros de paso alto y paso bajo. La codificación dio lugar a los vectores con los datos que serían utilizados en las redes neuronales. Todos estos pasos corresponden al pre procesamiento. Luego se diseñaron e implementaron las redes neuronales, las cuales se entrenaron y probaron con los esquemas de codificación propuestos.

4.2.3 Origen de los datos


Los sonidos utilizados en la realización del presente trabajo provienen en su mayoría de la colección de sonidos grabados en diferentes distritos de Lima durante los meses de enero a diciembre del 2017 así como muestras de audio grabadas en laboratorio usando la maqueta de un sistema real de abastecimiento de agua de un domicilio promedio.

A partir de un catálogo que contiene información general del contenido de las grabaciones se procedió a seleccionar un total de 300 muestras de audio de diferentes fechas.

El criterio principal fue el de encontrar sonidos que hubieran sido claros y en periodos de tiempo largos (1 minuto) o bien en varias ocasiones para asegurar una muestra lo más amplia posible.

Figura N° 29

Maqueta a tamaño real de una conexión domiciliaria



Fuente: Propia del autor

4.2.4 Pre Procesamiento

El pre procesamiento es la fase inicial del recorrido que siguieron los datos. Éste se compone a su vez de varias etapas que en trabajo se realizaron manualmente, que a la vez son previas y preparatorias a la fase de diseño y entrenamiento de las redes neuronales artificiales. Estos fueron:

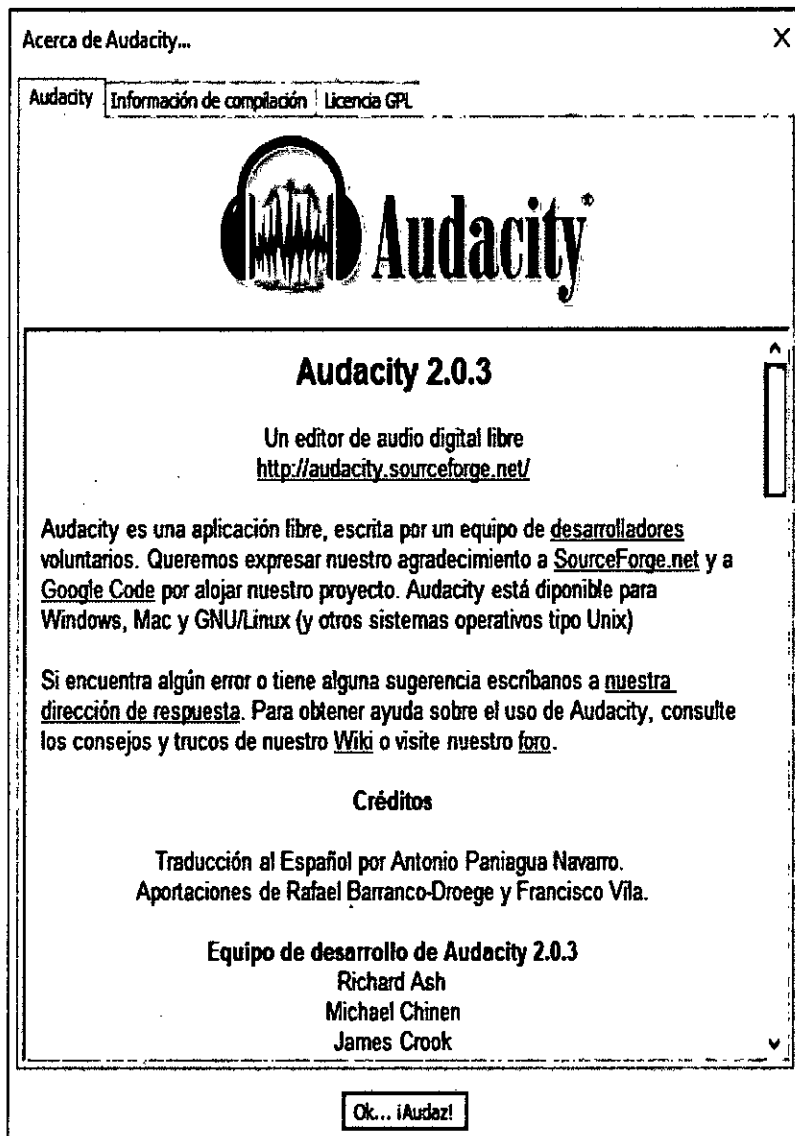
- Grabación digital de los sonidos
- Fragmentación de los sonidos
- Generación de espectrogramas (FFT)
- Aplicación de filtros y normalización de volúmenes
- Codificación de los sonidos

4.2.5 Grabación digital de los sonidos

Esta etapa consiste en obtener señales digitales a partir de las grabaciones originales. Esto implica discretizar, bajo ciertos parámetros, el conjunto continuo de valores que compone una señal analógica. Para realizar esto, se utilizó un Geófono Palmer conectada a la entrada de la tarjeta de sonido de la computadora mediante un cable de audio estéreo. Como interfaz se utilizó el Audacity, el cual es un programa diseñado para el manejo y tratamiento de sonidos de código abierto y de libre uso y distribución.

En todo el proceso deben especificar: la frecuencia de la muestra, el número de bits, y el booleano estéreo - mono. La frecuencia de la muestra se toma de 22.000 Hz y 44100 Hz. Si 1 Hz es la ocurrencia de un ciclo en un segundo, entonces 44100 Hz son esa magnitud de ciclos ocurridos en un segundo, o bien en nuestro caso, la toma de 44100 valores en cada segundo de la señal analógica de entrada. El número de bits tiene que ver con la calidad del audio muestreado puede ser 8 y 16 bits respectivamente la calidad es mejor pero el archivo será de mayor tamaño. Finalmente, el booleano mono-estéreo permite seleccionar entre uno o

Figura N° 30




Fuente: Software Audacity 2.0.3

dos canales respectivamente. Para fines prácticos se ha utilizado un solo canal, además de 16 bits por muestra y una frecuencia de muestreo de 44100 Hz.

Cabe indicar que los sonidos a identificar son de 3 tipos a los cuales denominaremos: *fuga en caja*, *fuga en línea* y *fuga en corporation* las cuales se muestran en la siguiente imagen para un mejor entendimiento.

Figura N° 31

Los tres tipos de fugas ubicados en una conexión domiciliar de agua



Fuente: Propia del autor

La fuga en Caja se refiere a las fugas de agua que se suscitan en el mismo buzón de la conexión domiciliar (medidor de agua) y las llaves de paso, llamadas llaves telescópicas, son las más comunes y las más fáciles de detectar.

La fuga en Línea se refiere a la tubería de PVC que normalmente es de ½ pulgada que sale desde el medidor de agua y se prolonga hasta la tubería matriz y puede tener una longitud variable que llegan hasta los 12 metros en algunos casos y la cual se encuentra a una profundidad de hasta 2 metros.

Su sonido es característico, pero no son visibles a simple vista y dependerá de la presión del agua y del tipo de terreno donde se encuentra la tubería para que sea fácil su escucha.

La fuga en Corporation se refiere al tramo de la tubería matriz generalmente de 4 a 32 pulgadas donde va colocada una abrazadera que servirá de conexión entre esta y la tubería de ½ pulgada de PVC.

Su sonido es característico, pero no son visibles a simple vista y dependerá de la presión del agua y del tipo de terreno donde se encuentra la tubería para que sea fácil su escucha.


4.2.6 Aplicación de filtros y normalización de la señal

El ruido de fondo puede presentar traslape o no con la señal de interés. Cuando este traslape ocurre, resulta muy difícil sino imposible eliminarlo y permanece como ruido que en este caso será parte de la información que será procesada por la red neuronal artificial. Cuando el ruido traslapa con la señal, es posible eliminarlo con filtros de paso alto o paso bajo o bien con otros algoritmos para supresión de ruido disponibles.

Basados en el rango de frecuencia de las fugas se procesaron todos los archivos con un filtro de paso alto a 1 KHz. y uno de paso bajo a 5 KHz. Con esto se eliminó todo ruido que hubiera sido grabado por debajo o sobre dichos valores. Luego de esto se han igualado los volúmenes de todos los archivos a 5 decibeles (dB). Este procedimiento toma el valor de amplitud pico de la señal original, o en otras palabras el valor de mayor intensidad de la grabación, y lo lleva a 5 decibeles, siendo este el nuevo volumen máximo.

Figura N° 32

Filtro y normalización de la señal



Fuente: MATLAB


4.2.7 Codificación mediante procesamiento de imágenes en Matlab

Las muestras de sonido se le generaron sus respectivos espectrogramas y se clasificaron en 3 carpetas una por cada tipo de fuga de agua. Las especificaciones utilizadas fueron: formato tif, con paleta de colores RGB y con una altura de imagen de 1024*728 píxeles.

Se hizo para cada una de las 300 muestras seleccionadas (100 por cada tipo de fuga de agua : caja , linea , corporation).

Figura N° 33

Conversión y normalización de archivos en Audacity




Fuente: Software Audacity 2.0.3

Luego se procedió en Matlab a generar los respectivos espectrogramas

```
[x, fs] = wavread('corporation1.wav')  
figure, spectrogram(x)
```

Figura N° 34

Generación del espectrograma en Matlab



Fuente: MATLAB

Posteriormente, teniendo todos los espectrogramas listos se procedió a procesarlos a través de algunas funciones programadas en el Matlab. El pseudocódigo que describe el algoritmo implementado se presenta a continuación:

Definir LARGO y ALTO del bloque Definir LARGO TOTAL para las imágenes Para todas las imágenes

Leer de la carpeta origen;

Guardarla temporalmente como objeto imagen indexado (matriz de posiciones con apuntador a mapa de colores);

Truncar el excedente de la matriz que sobrepase LARGO TOTAL establecido;

Traducir mapa de colores a un mapa simplificado (5 colores) y actualizar la matriz;

Recorrer la imagen por bloques de tamaño LARGO x ALTO y extraer color mayor (más intenso según orden definido);

Asignar el valor de color mayor a todos los píxeles del bloque;


Leer la matriz bloque por bloque y almacenar sus valores en un vector lineal de codificación;

Fin;

Así entonces, después la aplicación del procedimiento descrito, se obtuvo una imagen resultado y de ella una nueva matriz de $8 \times 15 = 120$ celdas. Cada valor contenido en las celdas se almacenó posteriormente en un vector de 120 elementos y esto se realizó para cada uno de los 300 archivos de sonido.

Figura N° 35

Simplificación del espectrograma tras el procesamiento



Fuente: Propia del autor


Posteriormente se redujo la dimensionalidad de estas matrices mediante una forma de compactación de la matriz en su eje vertical. Las ocho filas que componían dicho eje se redujeron a una, esto mediante la concatenación de los valores que compartían posición en cada columna. El orden de los dígitos dentro del nuevo valor obedece a un orden de posición vertical. Los valores más a la derecha corresponden con frecuencias bajas y los valores más a la izquierda a frecuencias altas. La posición de cada valor dentro de los vectores refleja el punto en el tiempo que dentro de la señal ocupaba cada uno de dichos valores.

4.2.8 Red Neuronal PMC con Imágenes (Variante Gradiente descendente con momentum)

Se utilizó inicialmente vectores de entrenamiento y validación compuestos por 120 elementos (codificación de imágenes) Como punto de partida se creó una red con 50 neuronas en la capa oculta y una tasa de aprendizaje de 0.1.

Figura N° 36

Red PMC utilizada estructura 120-50-5 con tansig y purelin



Fuente : nntool de MATLAB


Como vemos en la figura muestra una gran inestabilidad en la fase de entrenamiento de la red a pesar de esto se aprecia un descenso en el error medio cuadrático hasta

aproximadamente 0.1. Tras realizar la evaluación de esta red entrenada pobremente se obtuvo porcentajes de éxito de 17% (patrones de entrenamiento) y 3% (patrones desconocidos), considerados como porcentajes sumamente bajos.

Figura N° 37

Red PMC utilizada estructura 120-50-5 con tansig variante traingdm

Epochs 6000 de aprendizaje 0.1 y error cuadrático 0.001




Fuente : nntool de MATLAB

Luego de algunas pruebas con varias combinaciones del número de neuronas de capa oculta y la tasa de aprendizaje, se obtuvieron algunas redes que lograron alcanzar la convergencia en la fase de entrenamiento. Se lograron muy buenos porcentajes de éxito (100% con patrones de entrenamiento y 91% con patrones desconocidos).

Figura N° 38

Red PMC utilizada estructura 120-75-5 con tansig variante traingdm

Epochs 16000 de aprendizaje 0.01 y error cuadrático 0.001



Fuente : nntool de MATLAB

Un aspecto contrastante hasta este punto está relacionado con la tasa de aprendizaje. Al ser ésta una red más grande, lo que se observa es una tendencia a mejores resultados de entrenamiento mientras más pequeño sea el valor de la tasa de aprendizaje.

Resumen de los tiempos de entrenamiento y porcentajes de éxito en generalización para las redes traingdm PMC con codificación de imágenes. Los tiempos se expresan como minutos y segundos

Tabla N° 3

Resumen de los tiempos de entrenamiento y porcentajes de éxito en generalización para las redes traingdm PMC con codificación de imágenes. Los tiempos se expresan como minutos y segundos

Conformación	Tmin (minutos)	Tmax (minutos)	Tpromedio (minutos)	Porcentaje de Acierto
120-50-5	35.10	43.45	39.55	79 %
120-75-5	40.10	52.38	44.30	93 %
120-100-5	42.40	55.37	48.29	84 %

Fuente: propia del autor

Los porcentajes de éxito por tipo de fuga de agua no visible para la red PMC 120-75-3 se muestran en el cuadro siguiente. La única en la que la red falló fue la de caja mientras para las demás la clasificación fue casi perfecta.

Tabla N° 4

Porcentajes de éxito por fuga para la red PMC 120-75-3 traingdm.

Tipo de Fuga de Agua	# fugas	# clasificados			# clasificados correctos	Porcentaje de Acierto
		FC	FT	FCP		
Fuga en Caja (FC)	9	6	3	0	6	66 %
Fuga en Línea (FL)	16	0	16	0	16	100 %
Fuga en Corporation (FCP)	19	0	0	19	19	100%
Total	44				41	93%

Fuente: propia del autor

4.2.9 El equipo localizador inteligente será instaurado para que se reduzcan los porcentajes de agua no facturada por la empresa prestadora del servicio.

Se ha implementado usando una laptop i5 con el software Audacity y Matlab utilizando un geófono para capturar los sonidos y luego procesarlos y se contrasto los datos obtenidos con las lecturas que se encuentran en la base de datos **SGIO** de Sedapal encontrándose un equilibrio y un nivel de satisfacción con respecto a la detección de fugas por el procedimiento tradicional y la detección de fugas no visibles utilizando la red neuronal.

Figura N° 39

Software de Gestion de Incidencias operativas y comerciales SGIO

MANUAL Cerrar

gestión de incidencias operativas & comerciales GIOC

PRODUCCION - DBPROD
23/May/2018 04:57 am
Versión: B.02 - 01-05-2018

Usuario:

Contraseña:

Iniciar sesión

&Se olvidó la clave? Ingresar su Correo

Planes y Tableros GIS SGIOC

ETIC Equipo Tecnologías de la Información y Comunicaciones

Fuente: Sedapal

Figura N° 40

Contrastación de Detección de Fugas en el sistema Periodo Dic 2017

Inspecciones de Fugas Programadas															
Fecha Inicio:		01/12/2017 00:00		Fecha Termina:		31/12/2017 23:59		Buscar		Imprimir		Exportar		Cerrar	
<input type="text"/>											N° Registros:	697			
Tipo Fuga	Codigo	MIS	MIS Origen	Tipología	Estado Fuga	F Registro	F Programacion	F Revisión	Tiempo Aten.	Distrito					
PROGRAMADA	27579	5154742	0	LINEA D CAJA	OT FINALIZADA	29/12/2017 11:05:31	29/12/2017 00:00:00	29/12/2017 14:50:00	1	SAN MARTIN DE PORRES					
PROGRAMADA	27581	5152604	0	CAJA DAMED	GENERAR OT	30/12/2017 10:15:20	29/12/2017 00:00:00	29/12/2017 10:20:00	1	SAN MARTIN DE PORRES					
PROGRAMADA	27583	3732280	0	CAJA DAMED	GENERAR OT	30/12/2017 10:24:52	29/12/2017 00:00:00	29/12/2017 14:40:00	1	SAN MARTIN DE PORRES					
PROGRAMADA	27586	4128811	0	COFO	OT FINALIZADA	30/12/2017 11:13:07	29/12/2017 00:00:00	29/12/2017 09:40:00	1	LA MOLINA					
PROGRAMADA	27587	4088505	0	CAJA AMED	GENERAR OT	30/12/2017 11:13:25	29/12/2017 00:00:00	29/12/2017 10:50:00	1	LA MOLINA					
PROGRAMADA	27588	4012398	0	CAJA AMED	GENERAR OT	30/12/2017 11:15:51	29/12/2017 00:00:00	29/12/2017 11:21:00	1	LA MOLINA					
PROGRAMADA	27589	4118267	0	CAJA AMED	GENERAR OT	30/12/2017 11:16:14	29/12/2017 00:00:00	29/12/2017 14:31:00	1	LA MOLINA					
PROGRAMADA	27590	492172	0	LINEA A CAJA	OT FINALIZADA	30/12/2017 11:25:55	29/12/2017 00:00:00	29/12/2017 09:20:00	1	LA MOLINA					
PROGRAMADA	27591	5020607	0	VALVULA GRIFO	REVISADO CON FUGA	30/12/2017 11:26:41	29/12/2017 00:00:00	29/12/2017 10:00:00	1	LA MOLINA					
PROGRAMADA	27592	5395083	0	CAJA AMED	GENERAR OT	30/12/2017 11:27:54	29/12/2017 00:00:00	29/12/2017 10:25:00	1	LA MOLINA					
PROGRAMADA	27593	4117404	0	CAJA AMED	GENERAR OT	30/12/2017 11:28:27	29/12/2017 00:00:00	29/12/2017 11:25:00	1	LA MOLINA					
PROGRAMADA	27594	4176365	0	CAJA AMED	GENERAR OT	30/12/2017 11:29:02	29/12/2017 00:00:00	29/12/2017 12:00:00	1	LA MOLINA					
PROGRAMADA	27595	4117406	0	CAJA DAMED	GENERAR OT	30/12/2017 11:29:46	29/12/2017 00:00:00	29/12/2017 12:15:00	1	LA MOLINA					
PROGRAMADA	27596	5394943	0	CAJA AMED	OT FINALIZADA	30/12/2017 11:30:03	29/12/2017 00:00:00	29/12/2017 11:45:00	1	LA MOLINA					
PROGRAMADA	27597	4740533	0	CAJA DAMED	GENERAR OT	30/12/2017 11:33:40	29/12/2017 00:00:00	29/12/2017 14:30:00	1	LA MOLINA					
PROGRAMADA	27598	4143504	0	CAJA DAMED	GENERAR OT	30/12/2017 11:35:51	29/12/2017 00:00:00	29/12/2017 14:46:00	1	LA MOLINA					
PROGRAMADA	27599	4193051	0	CAJA DAMED	GENERAR OT	30/12/2017 11:36:28	29/12/2017 00:00:00	29/12/2017 15:00:00	1	LA MOLINA					
PROGRAMADA	27600	5335742	0	LINEA A CAJA	OT FINALIZADA	30/12/2017 11:51:39	29/12/2017 00:00:00	29/12/2017 09:51:00	1	VILLA MARIA DEL TRIUNFO					
PROGRAMADA	27602	2654684	0	CAJA AMED	GENERAR OT	30/12/2017 12:20:59	29/12/2017 00:00:00	29/12/2017 09:25:00	1	VILLA MARIA DEL TRIUNFO					
PROGRAMADA	27603	2654684	0	CAJA DAMED	GENERAR OT	30/12/2017 12:21:28	29/12/2017 00:00:00	29/12/2017 09:25:00	1	VILLA MARIA DEL TRIUNFO					
PROGRAMADA	27604	2654683	0	LINEA A CAJA	OT FINALIZADA	30/12/2017 12:22:01	29/12/2017 00:00:00	29/12/2017 09:37:00	1	VILLA MARIA DEL TRIUNFO					
PROGRAMADA	27605	2654037	0	CAJA AMED	GENERAR OT	30/12/2017 12:22:38	29/12/2017 00:00:00	29/12/2017 10:25:00	1	VILLA MARIA DEL TRIUNFO					
PROGRAMADA	27606	2654032	0	CAJA AMED	GENERAR OT	30/12/2017 12:23:11	29/12/2017 00:00:00	29/12/2017 11:40:00	1	VILLA MARIA DEL TRIUNFO					

Fuente: Sedapal

De los datos obtenidos de las fugas detectadas por el Operario Especializado vs el sistema de redes Neuronales se notó un porcentaje de acierto mayor al 93% con respecto al primero, cabe resaltar que aún no es concluyente por otros factores ajenos a la investigación que dificultan aumentar dicho porcentaje.

Figura N° 41

Detalle de la información con respecto a una Fuga Corporation 6000 Litros por día
Dic 2017

Inspecciones de Fugas Programadas

Fecha Inicio: 01/12/2017 00:00 Fecha Termino: 31/12/2017 23:59

Seleccion Detalle

Dirección: R. TULIPANES, LOS 217 F. 13 101 (DPTO 101)

Localidad: RB REMANSO DE LA MOLINA 2DA ETAPA, EL Control: C. 55 AV

Distrito: A MOLINA Sector: 191

Código: 27596 Solicitante: F Aviso: 30/12/2017 11:32:07 Ns Rad: 5394819 Aviso: 0

Operativo Responsable: CONTRATISTA CONSORCIO AGAL Nextel: VALIDADO

Observaciones Aviso:

Datos de Fuga

Tipo de Detección: PROGRAMADO EMERGENCIA Tipo de Rad: AGUA DESAGUE

Fecha de Registro: 30/12/2017 11:32 Fecha de Programación: 29/12/2017 00:00 Fecha de Revisión: 29/12/2017 14:10

Ubicación de Fuga: CORP Material de Red: PVC-U Diámetro: 20.00

Presión: 30 PSI Unidad - Lab Movil: 922 Recorrido de la Unidad: 0.0000 Caudal: 6,000.00

Deficiencias - Observaciones: CON FUGA

Observaciones Fugas:

Nro OT Sedapal: 30455806 Nro OT Contratista: 30455806 ESTADO: OT FINALIZADA

Observaciones Redes: 32-96141 CAP VERAMATOS 19.81.2611 - LARA

Fuente: Sedapal

Al contar con un sistema de gestión de base de datos SGIO el cual nos permite tener la información de cada fuga registrada y su respectivo proceso de reparación por parte del Contratista, el cual al terminar dicha reparación indica si efectivamente la fuga detectada era del tipo: caja, tubería o corporation o en su defecto indica que tipo de fuga se encontró o si no se encontró ninguna fuga (falso positivo).

Como ya se indicó anteriormente las reparaciones de las fugas corren por parte del Contratista el cual le factura a Sedapal los costos netos de dicha labor así se haya encontrado y reparado la fuga o no se haya encontrado la fuga.

Esto como vemos generan a Sedapal grandes costos extras debido a que no todas las fugas son reparadas debido a los errores que cometen los operarios especializados al detectar una fuga.

Así también como vemos muchas fugas no son detectadas por lo cual estas fugas de agua generan costos extras a Sedpal por agua no facturada a lo largo de los meses.

Se descargo la información histórica de un periodo de 1 Año (2017) para calcular la cantidad de ahorro debido a que se hizo el diagnóstico correcto de la fuga lo que permitió un ahorro porcentual de un 20 % en gastos del Contratista a cargo de dichas reparaciones.

Figura N° 42

Detalle Reporte Fugas 2017

Tipo Fuga	Codigos	NIS	NIS Origen	Tipología	Estado Fuga	F Registro	F Programacion	F Revision	Tiempo Ahorrado
PROGRAMADA	1943	176852	0	PERUANO	REVISADO SIN FUGA	02/01/2017 09:29:07	11/11/2016 00:00:00	02/01/2017 09:29:07	0
PROGRAMADA	1943	180727	0	CASA APED	REPARAR OT	02/01/2017 10:09:11	02/01/2017 00:00:00	02/01/2017 10:09:11	0
PROGRAMADA	1943	176852	0	PERUANO	REVISADO SIN FUGA	02/01/2017 10:01:41	02/01/2017 00:00:00	02/01/2017 10:01:41	0
PROGRAMADA	1943	181153	0	CASA APED	REPARAR OT	03/01/2017 09:52:22	02/01/2017 00:00:00	03/01/2017 09:52:22	0
PROGRAMADA	1943	1873101	0	COOP	OT FINALIZADA	03/01/2017 09:29:32	02/01/2017 00:00:00	03/01/2017 09:29:32	0
PROGRAMADA	1943	174939	0	COOP	OT FINALIZADA	03/01/2017 09:31:40	02/01/2017 00:00:00	03/01/2017 09:31:40	0
PROGRAMADA	1943	173996	0	LINEA DUCIA	OT FINALIZADA	03/01/2017 09:30:43	02/01/2017 00:00:00	03/01/2017 09:30:42	0
PROGRAMADA	1943	174982	0	LINEA DUCIA	OT FINALIZADA	03/01/2017 09:39:12	02/01/2017 00:00:00	03/01/2017 09:39:12	0
PROGRAMADA	1943	178915	0	LINEA DUCIA	OT FINALIZADA	03/01/2017 09:16:02	02/01/2017 00:00:00	03/01/2017 09:16:02	0
PROGRAMADA	1943	176852	0	COOP	OT FINALIZADA	03/01/2017 09:14:42	02/01/2017 00:00:00	03/01/2017 09:14:42	0
PROGRAMADA	1943	182997	0	LINEA DUCIA	OT FINALIZADA	03/01/2017 09:27:09	02/01/2017 00:00:00	03/01/2017 09:27:09	0
PROGRAMADA	1943	183995	0	CASA APED	REPARAR OT	03/01/2017 09:25:42	02/01/2017 00:00:00	03/01/2017 09:25:42	0
PROGRAMADA	1943	183943	0	CASA APED	REPARAR OT	03/01/2017 09:25:14	02/01/2017 00:00:00	03/01/2017 09:25:14	0
PROGRAMADA	1943	183943	0	CASA APED	REPARAR OT	03/01/2017 09:21:13	02/01/2017 00:00:00	03/01/2017 09:21:13	0
PROGRAMADA	1943	183943	0	COOP	OT FINALIZADA	03/01/2017 09:20:25	02/01/2017 00:00:00	03/01/2017 09:20:25	0
PROGRAMADA	1943	183943	0	CASA APED	FINALIZADO	03/01/2017 09:40:21	02/01/2017 00:00:00	03/01/2017 09:40:21	0
PROGRAMADA	1943	183943	0	LINEA DUCIA	OT FINALIZADA	03/01/2017 09:38:12	02/01/2017 00:00:00	03/01/2017 09:38:12	0
PROGRAMADA	1943	173996	0	CASA APED	FINALIZADO	03/01/2017 09:35:15	02/01/2017 00:00:00	03/01/2017 09:35:15	0
PROGRAMADA	1943	173996	0	COOP	FINALIZADO	03/01/2017 09:49:42	02/01/2017 00:00:00	03/01/2017 09:49:42	0
PROGRAMADA	1943	183943	0	LINEA DUCIA	OT FINALIZADA	04/01/2017 09:11:02	03/01/2017 00:00:00	04/01/2017 09:11:02	0
PROGRAMADA	1943	174982	0	LINEA DUCIA	OT FINALIZADA	04/01/2017 09:21:09	03/01/2017 00:00:00	04/01/2017 09:21:09	0
PROGRAMADA	1943	181435	0	CASA APED	FINALIZADO	04/01/2017 09:12:06	03/01/2017 00:00:00	04/01/2017 09:12:06	0

Fuente: Sedpal

4.3. Población y Muestra

En esta investigación predominantemente tecnológica, transversal, intitulada: "REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA" es importante delimitar sus alcances para su análisis correspondiente.

4.3.1 Unidad de análisis

La delimitación de la Unidad de Análisis del problema objeto de investigación, para detección de fugas no visibles en las redes de agua potable, utilizando redes neuronales, se ha determinado geográficamente como "unidad de análisis" a la ciudad de Lima en el periodo comprendido entre enero del 2017 a diciembre del 2017.

4.3.2 Población

En esta investigación se considera como población a las fugas de agua potable detectadas ya sean del tipo: Industriales, Comerciales y Residenciales, ubicados en la ciudad de Lima.

De esta gran muestra que son aproximadamente 6214 fugas detectadas e ingresadas al sistema SGIOC se procesaron algo más de 300 fugas de los 3 tipos Fuga en Caja, Fuga en Línea y Fuga en Corporation de diferentes distritos bajo la premisa de una presión de agua constante de entre 30 y 40 libras aproximadamente.

4.3.3 Tamaño de la Muestra

Para determinar probabilísticamente el "Tamaño de la Muestra" es necesario definir la característica principal de la población constituido por las fugas de agua potable detectadas en ese periodo de tiempo, que corresponde a una población "finita", de ($N = 300$) que es menor igual a el tamaño de la muestra de 6214 ($N \leq 6214$).

4.3.4 Prueba piloto

Debido a que no existen antecedentes de estudio correspondiente a esta investigación para determinar el tamaño de la muestra, se ha optado por descargar los datos obtenidos durante ese periodo de tiempo 1 año y procesarlos para verificar que porcentaje de las fugas seleccionadas fueron correctamente procesadas y cuales no y los tipos de fugas.

El procesamiento arrojó que solo el **60%** de las fugas fue detectado y catalogado correctamente en ese periodo de tiempo.

4.4. Procedimiento de recolección de datos

4.4.14 Algoritmo con Redes Neuronales Artificiales en MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.

Para el algoritmo de la red neuronal **PMC** se utilizó el software MATLAB.

Para ello, ha sido necesario desarrollar las siguientes actividades:

- Justificar el uso de la red Neuronal **PCM** para la detección de fugas no visibles de agua.
- Analizar las opciones de mejora, estableciendo las “bases de reglas”
- Seleccionar la muestra a utilizar según las diferentes variables como presión y distrito para tener una base de datos uniforme.
- Implementar la red neuronal **PCM** Perceptrón Multicapa (**Variante Gradiente descendente con momemtum**) para el procesamiento y reconocimiento de las fugas.
- Finalmente hacer pruebas en campo con ambos sistemas y ver la tasa de eficiencia de ambos.

4.4.2 La detección de fugas utilizando redes neuronales artificiales repercutirá en un mejor rendimiento del servicio reduciendo los porcentajes de agua no facturada.

Se implementó usando una laptop i5 con el software Audacity y Matlab además de un geófono para capturar los sonidos y luego procesarlos y se contrastó los datos obtenidos con las lecturas que se encuentran en la base de datos **SGIO** de Sedapal.

Se descargó la información histórica de un periodo de 12 meses Enero – Diciembre del 2017 para calcular la cantidad de ahorro debido a que se hizo el

diagnóstico correcto de la fuga lo que permitió un ahorro porcentual de un 20 % en gastos agua no facturada por parte de la empresa prestadora del servicio.

4.4.3 La contaminación sonora (ruido y el tipo de suelo donde se encuentra la tubería influyen en la detección de fugas.

Los factores intervinientes en la detección de fugas no visibles en las redes de agua potable que influyen en la captura de los sonidos utilizando el geófono son de 2 tipos contaminación sonora y tipo de terreno.

En el caso de la contaminación sonora por que distorsiona las lecturas sonoras obtenidas con el geófono.

En el caso de tipo de terreno (suelo) de algunos distritos de la ciudad de Lima los cuales son rellenos sanitarios, minimizan o atenúan en gran medida los sonidos capturados con el geófono.

4.4.4 Procesamiento estadístico y análisis de datos

El procedimiento estadístico a ser aplicado en esta investigación para explicar, demostrar y verificar lo planteado en la hipótesis, consistirá primeramente en las lecturas de la data obtenida llámese las fugas propiamente dichas obtenidas por el software de gestión de Fugas SGIOC durante el periodo comprendido entre enero del 2017 a diciembre del 2017

CAPÍTULO - 5

5. RESULTADOS

5.1 Modelando con MATLAB en las Redes Neuronales para la detección de fugas no visibles de agua potable en la ciudad de Lima.

Aplicando las redes neuronales con MATLAB a la detección de fugas no visibles de agua potable se pudo diseñar una red PCM que pudo detectar y reconocer las fugas de agua con una precisión del 93 % siendo mayor este porcentaje de precisión con respecto a su contraparte humana que es de aproximadamente de un 60%.

5.2 El equipo localizador inteligente será empleado para que se reduzcan los porcentajes de agua no facturada por la empresa prestadora del servicio.

Se descargo la información histórica de un periodo de 12 meses enero a diciembre del 2017 para calcular la cantidad de ahorro debido a que se hizo el diagnóstico correcto de la fuga lo que permitió un ahorro porcentual de un 20 % en gastos agua no facturada por parte de la empresa prestadora del servicio.

5.3 Determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima

Los factores intervinientes en la detección de fugas no visibles en las redes de agua potable que influyen en la captura de los sonidos utilizando el geófono son de 2 tipos contaminación sonora y tipo de terreno.

- En el caso de la contaminación sonora que afecta a la ciudad de Lima por que distorsiona las lecturas obtenidas con el geófono.
- En el caso de tipo de terreno (suelo) de algunos distritos de la ciudad de Lima los cuales son rellenos sanitarios, minimizan o atenúan en gran medida los sonidos capturados con el geófono, en algunos casos completamente.

CAPÍTULO - 6

6. DISCUSION DE RESULTADOS

6.1 Contrastación de la hipótesis con los resultados

En el capítulo III se estipula lo siguiente “Modelando con redes neuronales en Matlab se posibilitarán la explicación, demostración y probación de la hipótesis formulada”, para ello, se han identificado las variables: independiente, dependiente, e interviniente las cuales son definidas.

6.1.1 Algoritmo con Redes Neuronales Artificiales en MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.

Indicador: Sonidos capturados por el Geófono.

Es la variable independiente (X) el algoritmo (programa) el cual permitio de manera eficaz y eficiente la detección de las fugas, basado en los sonidos capturados por el geófono.

6.1.2 La detección de fugas utilizando redes neuronales artificiales repercutirá en un mejor rendimiento del servicio reduciendo los porcentajes de agua no facturada

Es la variable dependiente (Y) se estableció que la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima usando redes neuronales artificiales con MATLAB redujo los porcentajes de agua no facturada por la empresa prestadora del servicio en un 20%.

6.1.3 La contaminación sonora (ruido y el tipo de suelo donde se encuentra la tubería influyen en la detección de fugas

Es la variable interviniente (Z) la cual afecta directamente la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima.

6.2 Contratación de los resultados con otros estudios similares

Debido a su complejidad de las tres variables que definen este presente trabajo de Tesis, aplicando el “estado del arte de búsqueda de la información no se han encontrado estudios similares a la presente investigación.

CAPÍTULO - 7

7. CONCLUSIONES

7.1 Modelamiento con MATLAB en las Redes Neuronales para detectar fugas no visibles de agua potable en la ciudad de Lima.

Se comprobó que un modelamiento (algoritmo) basado en redes neuronales para la detección de fugas no visibles de agua era factible y que demostró que su eficiencia puede superar a la de un operario humano en un factor considerable y exento de los problemas y dificultades técnicas propias de dicha labor.

7.2 Emplear un equipo localizador inteligente para la detección de los sonidos de las fugas no visibles en las redes de agua potable en la ciudad de Lima reduciendo los porcentajes de agua no facturada por la empresa prestadora del servicio.

El diagnóstico correcto de la fuga por parte del equipo localizador inteligente permitió un ahorro porcentual de un 20 % en gastos por agua no facturada por parte de la empresa prestadora del servicio.

Este ahorro porcentual al utilizar el localizador inteligente luego de contrastarlo con los datos obtenidos del software SGIO repercute en beneficio de la empresa prestadora del servicio y que podrá esos recursos en proyectos de inversión y saneamiento en beneficio de todos.

7.3 Determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima

Los factores intervinientes en la detección de fugas no visibles en las redes de agua potable que influyen en la captura de los sonidos utilizando el geófono son de 2 tipos contaminación sonora y tipo de terreno.

- En el caso de la contaminación sonora que afecta a la ciudad de Lima por que distorsiona las lecturas obtenidas con el geófono, esto dificulta el procesamiento de la señal (sonido) obtenida.
- En el caso de tipo de terreno (suelo) de algunos distritos de la ciudad de Lima los cuales son rellenos sanitarios, minimizan o atenúan en gran medida los sonidos capturados con el geófono, en algunos casos completamente.

CAPÍTULO - 8

8. RECOMENDACIONES

Epistemológicamente para el futuro es preciso encomendar se siga investigando sobre este tema para futuras mejoras.

8.1 Modelado con Redes Neuronales en MATLAB para el reconocimiento y detección de fugas no visibles de agua potable en la ciudad de Lima.

El modelamiento usando redes neuronales artificiales es un campo que está en constante evolución por lo que esta investigación deberá continuar para mejorar el reconocimiento y la detección de fugas no visibles y superar los porcentajes de éxito obtenido.

8.2 Instaurar el equipo localizador inteligente para que se reduzcan los porcentajes de agua no facturada por la empresa prestadora del servicio.

Instaurar el equipo con el objetivo de reducir los costos utilizando para ello software libre, equipos más sensibles para la detección de los sonidos y hardware más pequeño que una laptop para el procesamiento de la información.

El ahorro porcentual dependerá en gran medida del compromiso de la empresa prestadora del servicio de agua potable para instaurar este sistema de forma que beneficie a toda la población en Lima y posteriormente replicar esto a todo el Perú.

8.3 Determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima

Se encontraron factores intervinientes en la detección de fugas no visibles en las redes de agua potable que influyen en la captura de los sonidos utilizando el geófono y son de 2 tipos contaminación sonora y tipo de terreno.

Se recomienda no construir núcleos poblacionales sobre rellenos sanitarios porque esto dificulta la detección de fugas ya que reduce considerablemente el sonido producido por estas.

Así mismo se recomienda un mayor control por parte de las municipalidades de la contaminación sonora especialmente la producida por el tráfico ya que esto distorsiona los sonidos capturados por el geófono y complica su posterior procesamiento.

9. REFERENCIAS BIBLIOGRÁFICAS

- DIRECTIVA N° 003-2012-R PARA LA PRESENTACIÓN DE PLANES DE TESIS Y TRABAJOS DE TESIS DE POSGRADO DE LA UNIVERSIDAD NACIONAL DEL CALLAO, aprobada con Resolución N° 877-2012-R del 17.10.2012.
- CONDORI, F., (2001). Sistema Híbrido Neurodifuso para la Evaluación de la Calidad del Software en un Proceso de Auditoría Informática. Revista de la Sociedad Peruana de Ciencias de la Computación.
- FAUCET, L., (1994). Fundamental of Neural Networks: Architectures, Algorithms and Applications. Prentice Hall International Inc, New Jersey. 296p.

- LAUDON, K., y LAUDON, J., (2000). Management Information Systems, Organization and Technology. Cuarta Edición, Editorial Prentice Hall Hispanoamericana..
- PANDYA, A., y MACY, R., (1996). Pattern Recognition with Neural Networks in C++. CRC Press, Boca Raton, Florida. USA.
- RUMELHART, D., et al., (1986). Learning Internal Representations by Error Propagation. The MIT Press, Cambridge, Massachusetts. USA.
- SANTÍN, G., (2000). Detección de Alumnos de Riesgo y Medición de la Eficiencia de Centros Escolares Mediante Redes Neuronales. Universidad Complutense de Madrid. España. 40p.
- SELLÉS, M., (2001). Optimización de una Bateria de Pruebas Mediante una Red Neuronal Artificial. Editorial Omega. 289p.
- STEINER, M., CARNIERI, C., y ROHERIG, C. (1993a). Diagnóstico Médico Via Programação Linear. Uberlandia, M.G, brasil
- STEINER, M., (1994). Reconhecimento de Padrão na Indústria de Papel. XXVI SBPO, Florianópolis.
- HILERA J, MARTÍNEZ V. 1995. Redes neuronales artificiales: fundamentos, modelos y aplicaciones. Madrid: Addison-Wesley Iberoamericana. RA-MA. 390p.
- SÁNCHEZ E, ALANIS A. 2006. Redes neuronales: conceptos fundamentales y aplicaciones a control automático. Madrid. Prentice-Hall. 210.

ANEXOS

• Matriz de Consistencia

TÍTULO: "REDES NEURONALES ARTIFICIALES APLICADAS A LA DETECCIÓN DE FUGAS NO VISIBLES EN LAS REDES DE AGUA POTABLE DE LA CIUDAD DE LIMA"				
PROBLEMAS	OBJETIVOS	HIPÓTESIS	VARIABLES	MÉTODOS
<p>PROBLEMA GENERAL</p> <p>¿Será posible utilizar un algoritmo con Redes Neuronales Artificiales en MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima?</p>	<p>OBJETIVO GENERAL</p> <p>Un modelo inteligente haciendo uso de Redes Neuronales Artificiales con MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima</p>	<p>HIPÓTESIS GENERAL</p> <p>Modelamiento inteligente haciendo uso de Redes Neuronales Artificiales con MATLAB, el cual permita la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.</p>	<p>VARIABLE: X (independiente)</p> <p>Algoritmo con Redes Neuronales Artificiales en MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.</p> <p>Indicador : Sonidos capturados por el Geófono.</p>	<p>Redes Neuronales con Matlab:</p> <p>El problema objeto de investigación, por ser predominantemente estadístico usando redes neuronales con MATLAB para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima.</p> <p>Los sonidos de las fugas serán procesadas utilizando el algoritmo diseñado para tal fin.</p>
<p>Prob. Espec. N° 1</p> <p>¿Será instaurado el equipo localizador inteligente para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima reduciendo los porcentajes de agua no facturada por la empresa prestadora del servicio?</p>	<p>Obj. Esp. N° 1</p> <p>Emplear un equipo localizador inteligente para la detección de los sonidos de las fugas no visibles en las redes de agua potable en la ciudad de Lima reduciendo los porcentajes de agua no facturada por la empresa prestadora del servicio.</p>	<p>Hip. Esp. N° 1</p> <p>El equipo localizador inteligente será instaurado para para que se reduzcan los porcentajes de agua no facturada por la empresa prestadora del servicio.</p>	<p>VARIABLE: Y (dependiente)</p> <p>La detección de fugas utilizando redes neuronales artificiales repercutirá en un mejor rendimiento del servicio reduciendo los porcentajes de agua no facturada.</p>	<p>Detección de Fugas:</p> <p>El equipo localizador inteligente será empleado y utilizando componentes electrónicos para la detección de fugas no visibles en las redes de agua potable en la ciudad de Lima reduciendo los porcentajes de agua no facturada por la empresa prestadora del servicio.</p>
<p>Prob. Espec. N° 2</p> <p>¿Se podrá determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima?</p>	<p>Obj. Esp. N° 2</p> <p>Determinar los factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima</p>	<p>Hip. Esp. N° 2</p> <p>Factores que afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima</p>	<p>VARIABLE: Z (interviniente)</p> <p>La contaminación sonora (ruido) y el tipo de suelo donde se encuentra la tubería influyen en el resultado final.</p>	<p>Factores que afectan la detección de fugas:</p> <p>Determinar estadísticamente qué factores afectan la detección de fugas no visibles en las redes de agua potable de la ciudad de Lima.</p>

• Cotejo de Estructuras del Plan de Tesis con la Tesis de Posgrado UNAC

ESTRUCTURAS METODOLÓGICAS DEL PLAN DE TESIS Vs. LA TESIS DE POSGRADO EN LA UNAC	
PLAN DE TESIS	TESIS (INFORME FINAL)
CARÁTULA	CARÁTULA
	PÁGINA DE RESPETO
	HOJA DE REFERENCIA DEL JURADO Y APROBACIÓN
	DEDICATORIA
	AGRADECIMIENTO
INDICE	ÍNDICE
	TABLAS DE CONTENIDO
INTRODUCCIÓN	RESUMEN
	ABSTRACT
I. PLANTEAMIENTO DEL PROBLEMA	I. PLANTEAMIENTO DE LA INVESTIGACIÓN
1.1 Determinación del problema (G. y E.)	1.1 Identificación del problema
1.2 Formulación del problema (G. y E.)	1.2 Formulación de problemas
1.3 Objetivos de la investigación	1.3 Objetivos de la investigación (G. y E.)
1.4 Justificación	1.4 Justificación
II. MARCO TEÓRICO	II. MARCO TEÓRICO
2.1 Antecedentes del estudio	2.1 Antecedentes del estudio
2.2 Marco teórico: Ontológico, Metodológico y Epistemológico	2.2 Fundamentos: Ontológico, Metodológico y Epistemológico
2.3 Definiciones de términos básico	2.3 Definición de términos
III. VARIABLES E HIPÓTESIS	III. VARIABLES E HIPÓTESIS
3.1 Definición de las variables	3.1 Definición de las variables
3.2 Operacionalización de variables	3.2 Operacionalización de variables
3.3 Hipótesis general e hipótesis específicas	3.3 Hipótesis general e hipótesis específicas
IV. METODOLOGÍA	IV. METODOLOGÍA
4.1 Tipo de investigación	4.1 Tipo de investigación
4.2 Diseño de la investigación	4.2 Diseño de la investigación
4.3 Población y muestra	4.3 Población y muestra
4.4 Técnicas e instrumentos de recolección de datos	4.4 Técnicas e instrumentos de recolección de datos
	4.5 Procedimientos de recolección de datos
4.5 Plan de análisis estadístico de datos	4.6 Procesamiento estadístico y análisis de datos
V. CRONOGRAMA DE ACTIVIDADES	V. RESULTADOS
VI. PRESUPUESTO	VI. DISCUSIÓN DE RESULTADOS
	6.1 Contrastación de hipótesis con los resultados
	6.2 Contrastación de resultados con otros estudios similares
	VII. CONCLUSIONES
	VIII. RECOMENDACIONES
VII. REFERENCIAS BIBLIOGRÁFICAS	IX. REFERENCIAS BIBLIOGRÁFICAS
ANEXOS	ANEXOS
• Matriz de consistencia	• Matriz de Consistencia
• Esquema tentativo de la tesis	• Otros anexos necesarios para respaldo de la investigación.
• Consentimiento informado	
CONCLUSIÓN FINAL	
DESARROLLADO EL PLAN DE TESIS AL 100 %, ÉSTE REPRESENTA UN AVANCE DE 60 A 70 % DEL INFORME FINAL DE LA TESIS	

Fuente: Directiva 2016 para Plan de Tesis e Informe Final de Tesis de Posgrado UNAC

%Generar Espectrograma en MATLAB

```
[x, fs] = wavread('corporation1.wav')  
figure, spectrogram(x)
```

Algoritmo para generar Matrices apartir de los espectrogramas

```
Definir LARGO y ALTO del bloque Definir LARGO TOTAL para las imágenes Para todas las  
imágenes  
Leer de la carpeta origen;  
Guardarla temporalmente como objeto imagen indexado (matriz de posiciones con  
apuntador a mapa de colores);  
Truncar el excedente de la matriz que sobrepase LARGO TOTAL establecido;  
Traducir mapa de colores a un mapa simplificado (5 colores) y actualizar la matriz;  
Recorrer la imagen por bloques de tamaño LARGO x ALTO y extraer color mayor (más  
intenso según orden definido);  
Asignar el valor de color mayor a todos los píxeles del bloque;  
Leer la matriz bloque por bloque y almacenar sus valores en un vector lineal de  
codificación;  
Fin;
```

```
% Read in input sub-images ul = imread('Lena_Upper_Left.jpg');
```

```
ur = imread('Lena_Upper_Right.jpg');
```

```
ll = imread('Lena_Lower_Left.jpg');
```

```
lr = imread('Lena_Lower_Right.jpg');
```

```
% Initialize a image buffer for final stitched image. [Row Col Layer] = size(ul); Output =  
zeros(Row * 2, Col * 2, Layer);
```

```
% Fill in four quadrants with sub-images (by assigning temporary matrices to target  
area of final image).
```

```
Output(1:Row,1:Row,:) = ul;
```

```
Output(1:Row,Row+1:2*Row,:) = ur;
```

```
Output(Row+1:2*Row,1:Row,:) = ll;
```

```
Output(Row+1:2*Row,Row+1:2*Row,:) = lr;
```

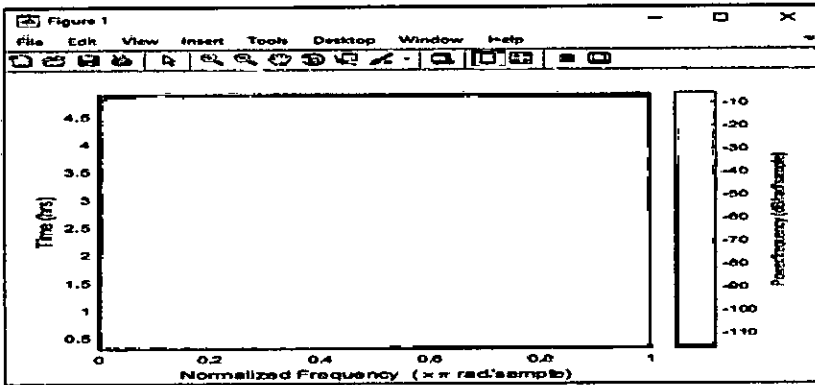
```
% Display Sub-images and Stitched Image subplot(2,2,1); imshow(ul); subplot(2,2,2);  
imshow(ur); subplot(2,2,3); imshow(ll); subplot(2,2,4); imshow(lr);
```

```
figure; imshow(uint8(Output));title('Stitchea Image');
```


```
% Save the final stitched image as a "corporation.bmp" file for later use.
```

```
imwrite(Output, 'corporation2.bmp');
```


ESPECTOGRAMA CAJA



ESPECTOGRAMA LINEA



ESPECTOGRAMA CORPORATION



FUGAS EN CAJA

0	0	0	0	0	1	1	0	0	0	1	0	1	0	1
0	0	0	0	0	1	1	0	0	0	1	0	1	1	0
0	0	0	0	0	1	1	0	0	0	1	0	1	1	1
0	0	0	0	0	1	1	0	0	0	1	1	0	0	0
0	0	0	0	0	1	1	0	0	0	1	1	0	0	1
0	0	0	0	0	1	1	0	0	0	1	1	0	1	0
0	0	0	0	0	1	1	0	0	0	1	1	0	1	1
0	0	0	0	0	1	1	0	0	0	1	1	1	0	0

FUGA EN LINEA

0	0	0	0	0	1	1	0	0	0	1	0	1	1	1
0	0	0	0	0	1	1	0	0	0	1	1	0	0	0
0	0	0	0	0	1	1	0	0	0	1	1	0	0	1
0	0	0	0	0	1	1	0	0	0	1	1	0	1	0
0	0	0	0	0	1	1	0	0	0	1	1	0	1	1
0	0	0	0	0	1	1	0	0	0	1	1	1	0	0
0	0	0	0	0	1	1	0	0	0	1	1	1	0	1
0	0	0	0	0	1	1	0	0	0	1	1	1	1	0

FUGA EN CORPORATION

0	0	0	0	0	1	1	0	0	0	1	1	1	1	1
0	0	0	0	0	1	1	0	0	1	0	0	0	0	0
0	0	0	0	0	1	1	0	0	1	0	0	0	0	1
0	0	0	0	0	1	1	0	0	1	0	0	0	1	0
0	0	0	0	0	1	1	0	0	1	0	0	0	1	1
0	0	0	0	0	1	1	0	0	1	0	0	1	0	0
0	0	0	0	0	1	1	0	0	1	0	0	1	0	1
0	0	0	0	0	1	1	0	0	1	0	0	1	1	0