

**RECONOCIMIENTO DE ARRITMIAS CARDIACAS CON LA APLICACIÓN DE
UNA RED NEURONAL**

CARLOS FERNANDO ARIZA CARVAJAL
DONALDO CÁRDENAS FLÓREZ

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
BUCARAMANGA
2004

**RECONOCIMIENTO DE ARRITMIAS CARDIACAS CON LA APLICACIÓN DE UNA RED
NEURONAL**

CARLOS FERNANDO ARIZA CARVAJAL
DONALDO CÁRDENAS FLÓREZ

Proyecto de grado para optar el título de Ingeniero Electrónico

Director

Mpe. JAIME BARRERO PÉREZ

Codirector

Ing. JAVIER GONZÁLEZ

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
BUCARAMANGA

2004

AGRADECIMIENTOS

Los autores expresan sus agradecimientos:

- A JAIME BARRERO PÉREZ. Mpe. Profesor de la escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones de la Universidad Industrial de Santander por su gestión como director de nuestro proyecto de grado.

- A Todos los profesores de la Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones por su inmejorable labor en el transcurso de nuestra formación profesional y personal.

- A Todas las personas y amigos que colaboraron en la realización del presente trabajo.

DEDICATORIA

A DIOS

A mis padres y hermanos por la paciencia y la esperanza
que han tenido en mi

CARLOS FERNANDO

A DIOS

A mi familia, que sin ella no hubiera sido posible cumplir
esta meta

DONALDO

OBJETIVOS

OBJETIVO GENERAL

Implementar un Electrocardioscopio Virtual capaz de adquirir (un registro electrocardiográfico desde una base de datos), procesar, visualizar las señales electrocardiográficas y desplegar resultados que faciliten la implementación de un sistema inteligente basado en Redes Neuronales que pueda clasificar, identificar y reconocer arritmias en tiempo real.

OBJETIVOS ESPECÍFICOS

- Generar una base de datos de registros electrocardiográficos con extensiones del tipo hoja de cálculo (*.xls) o del tipo texto (*.txt) (compatibles con Labview, Matlab y muchos lenguajes de análisis digital), pertenecientes a siete tipos de arritmias a saber: Bradicardia Sinusal, Taquicardia Supraventricular, Flúter Auricular, Fibrilación Auricular, Bigeminismo Ventricular, Trigemismo Ventricular y Taquicardia Ventricular.
- Extraer con el Electrocardioscopio Virtual (el cual fue implementado en lenguaje de programación LabVIEW utilizando un PC compatible IBM) características o patrones en el dominio del tiempo y la frecuencia de señales ECG previamente almacenados. Estas características son las siguientes:
 - Características temporales:
 - Cruces por cero,
 - 4 primeros coeficientes del modelo AR orden 16 de predicción lineal (LPC),

- Energía de la señal ECG en el dominio del tiempo (Teorema de Parseval),
- Valor rms de la señal ECG,
- Periodo (ms) comprendido entre dos o tres picos R (que es el equivalente al intervalo R-R su valor varía con la frecuencia cardiaca).

➤ Características frecuenciales:

Calculadas a partir de la FFT

- Ancho de banda al 95% de la energía,
- Desviación estándar
- Frecuencia Fundamental,

Calculadas a partir de la PSD (*Power Spectral Density*)

- Varianza,
- Media,
- Frecuencia Acumulada 50% de la energía
- Radios de Potencia

- Implementar dos arquitecturas de redes neuronales: *Backpropagation* y Redes de Base Radial (configuradas en Matlab) para ser entrenadas con base en todas las características o patrones temporales y frecuenciales de las señales ECG (provenientes de la base de datos), en la identificación en forma precisa de siete tipos diferentes de arritmias, que puedan ser detectadas y reconocidas en máximo tres ciclos cardiacos.

CONTENIDO

	Pag.
OBJETIVOS	4
INTRODUCCIÓN	17
1. CARACTERIZACIÓN DE LAS SEÑALES ECG	20
1.1 Descripción de la Señal Electrocardiográfica	20
1.1.1 Origen Fisiológico	20
1.1.2 Ondas componentes del ECG	22
1.1.3 Derivaciones	25
1.1.4 Patologías	25
1.1.4.1 Características Electrocardiográficas de las Arritmias	26
1.2 Base de datos de las señales electrocardiográficas	30
1.3 Clasificación de las señales ECG	33
1.3.1 Ritmo Cardíaco Normal (RCN).	34
1.3.2 Bradicardia Sinusal (SBR).	39
1.3.3 Fibrilación Auricular (AFIB)	43
1.3.4 Trigeminismo Ventricular (<i>Ventricular Trigeminy</i> , T).	47
1.3.5 Bigeminismo Ventricular (<i>Ventricular Bigeminy</i> , B).	51
1.3.6 Taquicardia Ventricular (<i>Ventricular Tachycardia</i> , VT).	55
1.3.7 Flúter Auricular (AFL).	59
1.3.8 Taquiarritmia Supraventricular (<i>Supraventricular Tachyarrhythmia</i> , SVTA)	63
1.4 Conclusión	67
2. APLICACIÓN CON REDES NEURONALES ARTIFICIALES EN EL RECONOCIMIENTO DE ARRITMIAS	72
2.1 Modelo de neurona artificial	72
2.1.1 Elementos básicos que componen una red neuronal	73
2.1.2 Funciones de Activación (<i>activation function</i>)	74
2.2 Preparación y codificación de los datos	77
2.2.1 Preprocesamiento de los datos de Entrenamiento	79
2.3 Topología de la <i>Red Backpropagation</i>	79
2.3.1 Justificación del tipo de Red Backpropagation	79
2.3.2 Especificación de la Arquitectura de la <i>Red Backpropagation</i>	80
2.3.3 Entrenamiento de la <i>Red Backpropagation</i>	80
2.4 Implementación del modelo de <i>Red Base Radial</i>	83
2.4.1 Entrenamiento de la Red Base Radial	83

	8
2.5 Pruebas del desempeño de la Red (<i>Backpropagation</i> y <i>Base Radial</i>)	84
2.5.1 Sensibilidad y Especificidad	86
2.6 Reentrenamiento de la Red	87
3. DESCRIPCIÓN DEL SOFTWARE EN LABVIEW	88
3.1 Electrocardioscopio Virtual	88
3.2 Procesamiento de la señal ECG	91
3.2.1 Ventaneo de la señal ECG	91
3.2.2 Filtrado de la señal ECG	93
3.2.3 Obtención del Espectro de la señal ECG	96
3.2.4 Otros módulos y sub-módulos	97
3.2.4.1 <i>Subvi</i> No. Zero.vi	97
3.2.4.2 <i>Subvi</i> Estadística tiempo.vi	98
3.2.4.3 <i>Subvi</i> Parseval.vi	98
3.2.4.4 <i>Subvi</i> AR.vi	99
3.3 Conformación de los Patrones temporales y frecuenciales	99
4. ANÁLISIS DE DESEMPEÑO DE LA RED NEURONAL	102
4.1 Selección de los datos de Entrenamiento y Validación	102
4.2 Configuración de la Red <i>Backpropagation</i> con el mejor desempeño	102
4.2.1 Análisis en la Fase de Entrenamiento y Validación	103
4.2.2 Inclusión de una nueva capa oculta	107
4.2.3 Análisis en la fase de Entrenamiento, Validación y Prueba	109
4.3 Evaluación de desempeño de la <i>Red Base Radial</i>	118
CONCLUSIONES	120
RECOMENDACIONES	125
BIBLIOGRAFÍA	127

LISTA DE FIGURAS

		Pag.
FIGURA 1	Estructura genérica del sistema de control nervioso del corazón	21
FIGURA 2	Ondas componentes y principales intervalos de la señal electrocardiográfica	24
FIGURA 3	Ritmo cardiaco normal (<i>Normal sinus rhythm</i>)	34
FIGURA 4	Espectro en frecuencia del Ritmo cardiaco normal	34
FIGURA 5	Ritmo cardiaco normal y su Espectro frecuencial	37
FIGURA 6	Bradicardia Sinusal (<i>Sinus Bradycardia</i>)	39
FIGURA 7	Espectro en frecuencia de la Bradicardia Sinusal	40
FIGURA 8	Bradicardia Sinusal y su Espectro frecuencial	41
FIGURA 9	Fibrilación Auricular (<i>Atrial Fibrillation</i>)	43
FIGURA 10	Espectro en frecuencia de la Fibrilación Auricular	44
FIGURA 11	Fibrilación Auricular y su Espectro frecuencial	45
FIGURA 12	Trigeminismo Ventricular	47
FIGURA 13	Espectro en frecuencia del Trigeminismo Ventricular	48
FIGURA 14	Señal Trigeminismo Ventricular y su Espectro frecuencial	49
FIGURA 15	Bigeminismo Ventricular	51
FIGURA 16	Espectro en frecuencia del Bigeminismo Ventricular	52
FIGURA 17	Señal Bigeminismo Ventricular y su Espectro frecuencial	53
FIGURA 18	Taquicardia Ventricular (VT)	55
FIGURA 19	Espectro en frecuencia de Taquicardia Ventricular	56
FIGURA 20	Señal Taquicardia Ventricular y su Espectro frecuencial	57
FIGURA 21	Flúter Auricular (<i>Atrial flutter</i>)	59
FIGURA 22	Espectro en frecuencia del Flúter Auricular (AFL)	60
FIGURA 23	Señal Flúter Auricular y su Espectro frecuencial	61
FIGURA 24	Taquiarritmia Ventricular	62
FIGURA 25	Espectro en frecuencia de la Taquiarritmia Ventricular	64
FIGURA 26	Señal Taquiarritmia Supraventricular y su Espectro Frecuencial	65
FIGURA 27	Modelo de una neurona artificial	70

FIGURA 28	Ejemplo de una red neuronal totalmente conectada	71
FIGURA 29	Función de activación lineal	72
FIGURA 30	Función de activación Sigmoidea	72
FIGURA 31	Función de activación tangente Hiperbólica	73
FIGURA 32	Función de activación <i>gaussiana</i>	73
FIGURA 33	Función de activación escalón	73
FIGURA 34	Panel frontal del Electrocardioscopio Virtual	87
FIGURA 35	Código gráfico del instrumento	90
FIGURA 36	Panel frontal del Electrocardioscopio Virtual Señal ECG ventaneada	92
FIGURA 37	Módulo windows.vi (Ventaneo)	93
FIGURA 38	Panel frontal del Electrocardioscopio Virtual Controles de filtrado	94
FIGURA 39	Módulo Filtro.vi	95
FIGURA 40	Panel frontal del Electrocardioscopio Virtual Distribución frecuencia de una señal ECG	96
FIGURA 41	Módulo Análisis Frecuencia.vi	97
FIGURA 42	Módulo No. Zero.vi	98
FIGURA 43	Módulo Estadística tiempo.vi	98
FIGURA 44	Módulo Parseval.vi	99
FIGURA 45	Módulo AR.vi	99
FIGURA 46	Código gráfico del Electrocardioscopio Virtual	100
FIGURA 47	Módulo Neural Network.vi	101
FIGURA 48	Error cuadrático medio para la combinación de neuronas de entrada y neuronas ocultas utilizadas en la fase de Entrenamiento y Validación.	104
FIGURA 49	Error cuadrático medio para la combinación de dos capas ocultas de neuronas y una de salida en la fase de Entrenamiento y validación	108
FIGURA 50	Error Absoluto Promedio para la combinación de dos capas ocultas de neuronas y una de salida en la fase de Entrenamiento y Validación	111
FIGURA 51	Desviación máxima para la combinación de dos capas	112

	ocultas de neuronas y una de salida en la fase de Entrenamiento y Validación	
FIGURA 52	Error cuadrático medio para el proceso de simulación utilizando fase de Entrenamiento, Validación y Prueba	114
FIGURA 53	Error absoluto promedio para el proceso de simulación utilizando fase de Entrenamiento, Validación y Prueba	114
FIGURA 54	Error de Desviación Máxima para el proceso de simulación utilizando fase de entrenamiento, validación y prueba	115
FIGURA 55	Iteraciones vs. Error en la clasificación de los patrones para la configuración de red 21-32-24-1	117

LISTA DE TABLAS

		Pag.
TABLA 1	Duración del intervalo QT	25
TABLA 2	Características temporales del Ritmo Cardíaco Normal	35
TABLA 3	Coeficientes de Predicción Lineal (LPC) del RCN	35
TABLA 4	Características del espectro frecuencial del RCN	36
TABLA 5	Características temporales y frecuenciales del RCN	36
TABLA 6	Patrones pertenecientes a otras 14 señales del RCN	38
TABLA 7	Características temporales de la Bradicardia Sinusal (SBR)	39
TABLA 8	Coeficientes de predicción lineal de SBR	39
TABLA 9	Características del espectro frecuencial de SBR	40
TABLA 10	Características temporales y frecuenciales de SBR	40
TABLA 11	Patrones pertenecientes a otras 14 señales de SBR	42
TABLA 12	Características temporales de la Fibrilación Auricular (AFIB)	43
TABLA 13	Coeficientes de Predicción Lineal de AFIB	43
TABLA 14	Características del espectro frecuencial de AFIB	44
TABLA 15	Características temporales y frecuenciales de AFIB	45
TABLA 16	Patrones pertenecientes a otras 14 señales de AFIB	46
TABLA 17	Características temporales de Trigeminismo Ventricular	47
TABLA 18	Coeficientes de predicción lineal de Trigeminismo Ventricular	47
TABLA 19	Características del espectro frecuencial de Trigeminismo Ventricular	48
TABLA 20	Características temporales y frecuenciales de Trigeminismo Ventricular	49
TABLA 21	Patrones pertenecientes a otras 14 señales de Trigeminismo Ventricular	50
TABLA 22	Características temporales de Bigeminismo Ventricular	51

TABLA 23	Coeficientes de predicción lineal de Bigeminismo Ventricular	51
TABLA 24	Características del espectro frecuencial de Bigeminismo Ventricular	52
TABLA 25	Características temporales y frecuenciales de Bigeminismo Ventricular	53
TABLA 26	Patrones pertenecientes a otras 14 señales de Bigeminismo Ventricular	54
TABLA 27	Características temporales de Taquicardia Ventricular (VT)	55
TABLA 28	Coeficientes de predicción lineal de Taquicardia Ventricular	55
TABLA 29	Características del espectro frecuencial de VT	56
TABLA 30	Características temporales y frecuenciales de VT	57
TABLA 31	Patrones pertenecientes a otras 14 señales de VT	58
TABLA 32	Características temporales de Flúter Auricular (AFL)	59
TABLA 33	Coeficientes de predicción lineal de Flúter Auricular	59
TABLA 34	Características del espectro frecuencial de Flúter Auricular	60
TABLA 35	Características temporales y frecuenciales de Flúter Auricular	61
TABLA 36	Patrones pertenecientes a otras 14 señales de AFL	62
TABLA 37	Características temporales de Taquiarritmia Supraventricular	63
TABLA 38	Coeficientes de predicción lineal de Taquiarritmia Supraventricular (SVTA)	63
TABLA 39	Características del espectro frecuencial de SVTA	64
TABLA 40	Características temporales y frecuenciales de la señal Taquiarritmia Supraventricular	65
TABLA 41	Patrones pertenecientes a otras 14 señales de SVTA	66
TABLA 42	Rango de valores de los parámetros temporales y frecuenciales de las siete arritmias cardíacas y el ritmo cardíaco normal	69
TABLA 43	Patrones temporales y frecuenciales pertenecientes a las siete clases de arritmias y el ritmo cardíaco normal	76

TABLA 44	Codificación de acuerdo a las clases de arritmias	78
TABLA 45	Registros de la base de datos de arritmias (<i>Arrhythmia Database</i>)	85
TABLA 46	Resultados de la detección de los latidos de la MIT/BIH Database	86
TABLA 47	Resultados de Sensibilidad y Especificidad de los latidos de la MIT/BIH database	87
TABLA 48	Resultados del Error Cuadrático Medio para el proceso de simulación utilizando fase de entrenamiento y validación	105
TABLA 49	Resultados del Error Absoluto Promedio para el proceso de simulación utilizando fase de entrenamiento y validación	105
TABLA 50	Resultados de Desviación Máxima para el proceso de simulación utilizando fase de entrenamiento y validación	105
TABLA 51	Resultados del Error para el proceso de simulación con la combinación de dos capas ocultas de neuronas y una de salida utilizando fase de entrenamiento y validación	108
TABLA 52	Errores en el proceso de simulación para la etapa de validación para las seis diferentes configuraciones de red seleccionadas utilizando fase de entrenamiento, validación y prueba	116
TABLA 53	Errores en el proceso de simulación para la etapa de entrenamiento para las seis diferentes configuraciones de Red seleccionadas utilizando fase de entrenamiento, validación y prueba	116
TABLA 54	Errores en el proceso de simulación para la etapa de prueba para las seis diferentes configuraciones de red seleccionadas utilizando fase de entrenamiento, validación y prueba	117
TABLA 55	Resultados del Error para el proceso de simulación de la red de Base Radial en la fase de entrenamiento y validación	118

LISTA DE ANEXOS

	Pag.
Anexo A Historia de las Redes Neuronales	133
Anexo B Clasificación de las redes según la información de entrada	135
Anexo C Redes Neuronales más conocidas	136
Anexo D Algoritmos de aprendizaje más conocidos	138
Anexo E Descripción de las Funciones Utilizadas en Matlab	139
Anexo F Valores de cortes de frecuencia del tipo de filtro escogido	147
Anexo G Ondas, Segmentos y Complejos Electrocardiográficos	148
Anexo H Derivaciones	150
Anexo I Patologías	153
Anexo J Instrumento Virtual	155
Anexo K Teoría de Redes Neuronales	158
Anexo L Tratamiento digital de la señal	234
Anexo M Pruebas al sistema	259

TÍTULO: RECONOCIMIENTO DE ARRITMIAS CARDIACAS CON LA APLICACIÓN DE UNA RED NEURONAL*

AUTORES

ARIZA C. Carlos Fernando

CÁRDENAS F. Donaldo**

PALABRAS CLAVES

Tratamiento de Señales, LabVIEW, Procesamiento Digital, Análisis Espectral, Adquisición, Filtrado y Ventaneo, Red Neuronal Artificial, Identificación de Arritmias.

DESCRIPCIÓN

Se construyó un Electrocardioscopio Virtual basado en programación gráfica de LabVIEW que permite adquirir señales electrocardiográficas, procesar y desplegar los resultados en tiempo real. Además en este instrumento virtual se implementó una red neuronal con ayuda de Matlab que clasifica y reconoce siete tipos de arritmias.

En el primer capítulo se describen las principales características de la señal ECG, sus ondas componentes y sus intervalos. Como una segunda parte de este capítulo se hace una caracterización más específica de las señales ECG, presentado 14 características temporales y frecuenciales para siete arritmias a estudiar, observando parámetros que puedan diferenciar a cada arritmia.

En el capítulo segundo se presentará un estudio centrado en el entrenamiento y simulación de la red neuronal así como los comandos utilizados en Matlab para crear la red (*Backpropagation* y Base Radial) con sus diferentes opciones de configuración.

En el tercer capítulo se realiza una presentación general de como funciona este Electrocardioscopio Virtual, donde se exponen sus especificaciones, la descripción de los *subvi* que realizaron el procesamiento de las señales cardiacas así como los indicadores que desplegaron las señales resultantes y la presentación de los cálculos del procesamiento de la señal ECG que van a ser introducidos en la red neuronal para que pueda hacer el reconocimiento de las arritmias.

En el cuarto capítulo se presentarán y analizarán los resultados obtenidos en la exploración de las diferentes configuraciones de la red *Backpropagation* hasta encontrar la de mejor desempeño. Este análisis se efectuó comparando resultados con la experiencia obtenida por la *Red de Base Radial*.

* Proyecto de Grado.

** Facultad de Ingenierías Físico-Mecánicas, Escuela de Ingenierías Eléctrica, Electrónica y Telecomunicaciones, Director de Proyecto: Ing. Mpe. Jaime Barrero Pérez.

TITLE: CARDIAC ARRHYTHMIAS RECOGNIZING WITH THE APPLICATION OF A NEURAL NETWORK***AUTHORS****ARIZA C. Carlos Fernando****CÁRDENAS F. Donaldo******KEY WORDS**

Signal Processing, LabView, Digital Processing, Spectral Analysis, Acquisition, Filtrate and windowed, Artificial Neural Network, arrhythmias Identification.

ABSTRACT

A Virtual Electrocardioscopy was built based on LabVIEW graphic program that allow the acquisition electrocardiographic signals, processing and display the results in real time. Besides in this virtual tool it was added a neural network whit the Matlab help that classify and recognize seven different types arrhythmias.

In the first chapter it is described the main characteristic of the ECG signal, its waves components and its intervals. As a second part of this chapter a more specified characterization of ECG signals is done, this one shows fourteen temporary characteristics and frequential for seven arrhythmias to study, looking parameters that could differentiate each arrhythmia.

In the second chapter it is showed a study based on the training and simulation of the neural network in the same way the commands used in Matlab for creating the network (Backpropagation and Radial Base) with their different configuration programs.

In the third chapter it is done a general presentation of how this Virtual Electrocardioscopy works, where proper specifications, such as the *subvi* that made the cardiac signals processing that's the indicators that display the resulting signals ECG which are going to be introduce in the neural network for recognizing the arrhythmias.

In the quarter chapter it will be presented and analyzed the obtained results in the exploration of the different Backpropagation network configuration as far as finding this one with the best performance. This analysis was done comparing results with the obtained experience for the Radial Base Network.

* Grade Project

** Mechanics Physical Faculty, Electric, Electronic and Telecommunications Engineering School. D. Project: Eng. Mpe. Jaime Barrero Pérez

INTRODUCCIÓN

Las redes neuronales pueden usarse para varias tareas relacionadas con el tratamiento de señales (reconocimiento de señales de radar, compresión de imágenes, predicción de datos atmosféricos, etc.). Como caso particular del tratamiento de señales está el tratamiento de señales biológicas. Dentro de este campo pretendemos abordar el problema del reconocimiento de arritmias cardíacas.

Es bien conocida la importancia de la señal electrocardiográfica para el diagnóstico de enfermedades cardíacas mediante inspección visual. La adquisición de registros de larga duración, hablamos de registros que pueden tener 24, 48 horas o más, la cantidad de latidos a examinar para identificar arritmias u otra anomalía por parte del cuerpo médico puede llegar a ser de varios miles, lo cual hace de esta tarea un proceso laborioso y complejo.

La inteligencia artificial pretende acercar el comportamiento de las máquinas al comportamiento humano; esto pretende liberar al hombre de tediosas tareas que hasta ahora sólo él podía realizar. De ahí nace el interés por parte nuestra en el estudio de las técnicas de tratamiento de señales y la inquietud de que esta inspección (reconocimiento de arritmias) que se hace de forma visual se pueda también hacer de forma automática, por la dificultad que entraña su análisis manual; además como una continuación del trabajo de proyecto de grado¹ Analizador de Espectro Virtual (AEV), en el cual se realizó una aplicación médica de reconocimiento de señales cardíacas de forma estadística.

¹ Proyecto de grado “Analizador de Espectro Virtual” desarrollado por POSADA Edwin y CASTRO Henry. Colombia, Universidad Industrial de Santander, 2000.

Es así como se construyó un Electrocardioscopio Virtual usando un PC compatible, basado en programación gráfica de LabVIEW², que permite adquirir (ya sea desde una base de datos o una tarjeta de adquisición de datos), procesar, y desplegar los resultados de las señales electrocardiográficas en tiempo real. Además es este instrumento virtual se implementó³ una red neuronal con ayuda de Matlab⁴, que clasifica, reconoce e identifica siete tipos diferentes de arritmias cardiacas.

Este trabajo está organizado en 4 capítulos, con el siguiente contenido:

En el primer capítulo se describen, en un primera parte, las principales características de la señal electrocardiográfica, sus ondas componentes y sus intervalos. Como una segunda parte de este capítulo se hace una caracterización más específica de las señales ECG, presentado 14 características temporales y frecuenciales para siete arritmias a estudiar, observando parámetros que puedan diferenciar cada arritmia para su posterior identificación de acuerdo a estas características o patrones.

En el segundo capítulo se presentará un estudio centrado en el entrenamiento y simulación de la red neuronal (en base a la matriz formada por todos los patrones temporales y frecuenciales de las señales ECG analizadas), así como los comandos utilizados en Matlab para crear la red (*Backpropagation* y Redes de Base Radial) con sus diferentes opciones de configuración: número de neuronas, función de transferencia para cada una de las capas, algoritmo de entrenamiento, función de actualización de los pesos, función para evaluar el desempeño de la red.

En el tercer capítulo se realiza una presentación general de cómo funciona este Electrocardioscopio Virtual, donde se exponen especificaciones propias de este

² Producto de *National Instruments*, adquirido por la Universidad como apoyo y fortalecimiento en las líneas de investigación y enseñanza en las áreas de Ingeniería Eléctrica y Electrónica.

³ LabVIEW permite alternar por medio de una herramienta llamada *script*, el procesamiento con Matlab.

⁴ Utilización del toolbox de redes neuronales.

como la descripción de los *subvi* (o módulos) que realizaron el procesamiento de las señales cardiacas (filtrado y ventaneo), así como los indicadores que desplegaron las señales resultantes (señal electrocardiográfica y espectro de la señal electrocardiográfica) y la presentación de los cálculos del procesamiento de la señal ECG (extracción de características o patrones temporales y frecuenciales) que van a ser introducidos en la red neuronal para que pueda hacer el reconocimiento de las arritmias.

En el capítulo cuarto se presentarán y analizarán los resultados obtenidos en la exploración de las diferentes configuraciones de la red *Backpropagation* hasta encontrar la de mejor desempeño. Este análisis se efectuó comparando resultados con la experiencia obtenida por la *Red de Base Radial (RBF)*.

1. CARACTERIZACIÓN DE LAS SEÑALES ECG

1.1 Descripción de la Señal Electrocardiográfica

La descripción se realizará sobre aquellos aspectos más destacados, sin profundizar desde el punto de vista médico, ya que ese no es el objetivo del presente trabajo.

1.1.1 Origen Fisiológico

El electrocardiograma (en adelante ECG), es una representación gráfica de la actividad eléctrica del corazón que ofrece información acerca del estado del músculo cardíaco⁵. Esta representación consiste en una línea de base y varias deflexiones y ondas. El origen se encuentra en las células del músculo cardíaco, las cuales pueden ser excitadas eléctricamente, produciéndose un trasiego de iones a través de su membrana, lo cual induce un potencial eléctrico variable en el interior y en el exterior.

El corazón se contrae únicamente si el músculo cardíaco cambia la conductividad de su pared celular, permitiendo un flujo de iones de Calcio como elemento más característico dentro de un complejo proceso. En general la contracción es disparada por el nodo sinusal, situado en la posición cefálica de la aurícula derecha y compuesto por un grupo de células que tienen como característica peculiar que se despolarizan automáticamente cada 800ms. Esta despolarización se transmite a las células auriculares adyacentes, describiendo un flujo de cationes Na^+ y Ca^{++} , que irrumpen desde el medio extracelular hacia el interior cuando la membrana se hace permeable. La fase de recuperación se conoce como repolarización, y durante este periodo las concentraciones de iones vuelven al nivel normal. En reposo las células tienen

⁵ WILCHES, Mauricio. Principios Básicos de Fisiología. Tomo II. Colombia, Universidad Antioquia, 1991

un potencial transmembrana de 90mV. Este potencial es cíclico, con un periodo de entre 400 y 1200ms. Existe una conexión especial, el nodo auriculoventricular o AV, que avanza de aurícula a ventrículo, evitando frecuencias cardiacas superiores a 200 lpm (latidos por minuto). En la figura 1 se muestra la estructura genérica del sistema nervioso del corazón, donde se indican los elementos mencionados.

La despolarización del músculo produce un nivel positivo que precede a la onda de avance. Esto significa que en la superficie del músculo los electrodos recogen un nivel positivo. La amplitud de la deflexión es proporcional a la masa de músculo, lo cual permite detectar, por ejemplo, pacientes con los ventrículos derecho o izquierdo agrandados (Hipertrofia ventricular).




Figura 1. Estructura genérica del sistema de control nervioso del corazón.⁶

⁶ Tesis Doctoral. Autor: Alfredo Rosado Muñoz. “Desarrollo de Técnicas de Detección de Fibrilación Ventricular Basadas en algoritmos Tiempo-Frecuencia”. Facultad de Ciencia Físicas Departamento de Ingeniería Electrónica. Universidad de Valencia, 2000

La señal *Holter* corresponde a un registro electrocardiográfico continuo de 24 ó 48 horas. Esta señal permite un mayor control de la evolución de un paciente a lo largo de un periodo relativamente grande de tiempo, evitando la falta de información que aparece en un electrocardiograma normal debido a su corta duración. Es importante resaltar que la señal *Holter* está formada por centenares de miles de ondas cada una correspondiente a un latido, lo cual hace imposible el examen detallado de todas y cada una de ellas mediante inspección visual.

1.1.2 Ondas componentes del ECG

Durante la despolarización y repolarización miocárdica, aparecen las ondas del ECG. Las distancias entre deflexiones u ondas se denominan segmentos o intervalos. Un periodo del ECG perteneciente a un individuo sano, consiste en una onda P, el complejo QRS, la onda T y la onda U, tal como se muestra en la figura 2.

Las porciones del electrocardiograma entre las deflexiones se denominan segmentos, y las distancias entre ondas se denominan intervalos. El ECG puede ser dividido en los siguientes intervalos y segmentos.

- *Onda P*. Representa la despolarización de la aurícula. Su duración normal es de 0.1s. La forma depende de la localización de los electrodos (derivación). Un aumento del voltaje o de la duración de esta onda indica una anomalía auricular. La ausencia de esta onda ocurre en una parada del nodo sinusal, y en el bloqueo SA sinoauricular (situación en la que sí se despolariza el nodo sinusal, pero no se transmite el impulso a las células de la aurícula contiguas).

- *Complejo QRS*. Representa la despolarización de los ventrículos. Está formado por las ondas Q, R y S, aunque se pueden presentar otras denominadas R' y S'. Su duración es de aproximadamente 100ms.
- *Onda T*. Representa la repolarización de los ventrículos. La onda T normal es asimétrica en sus ramas y está redondeada en su vértice. La pendiente de la rama inicial es más suave que la de la rama terminal. Las anomalías de esta onda pueden indicar enfermedades cardíacas primarias, aunque hay casos de personas sanas con las mismas anomalías. También puede traducir trastornos del equilibrio hidroelectrolítico.
- *Onda U*. Tiene un origen fisiológico poco claro. Es anormal en trastornos del potasio.
- *Segmento PR*. Corresponde a la línea isoelectrica entre el comienzo de la onda P y la deflexión inicial del complejo QRS. La duración normal de este segmento está entre 0.12 y 0.21s, dependiendo de la frecuencia cardíaca.
- *Segmento ST*. Es el intervalo entre el final del complejo QRS y el inicio de la onda T. Representa el tiempo durante el que los ventrículos permanecen en estado activado y puede iniciarse la repolarización ventricular. Normalmente el segmento ST es isoelectrico, aunque puede estar también ligeramente desviado. Una desviación elevada a menudo representa un infarto de miocardio, una pericarditis aguda o una miocarditis.
- *Intervalo PP*. Corresponde al intervalo de tiempo entre el comienzo de la onda P y el comienzo de la siguiente onda P.
- *Intervalo RR*. Corresponde al intervalo de tiempo entre la onda R de un complejo QRS y la onda R del siguiente complejo QRS.

- *Intervalo QRS*. Corresponde al intervalo de tiempo entre el comienzo de la onda Q y el final de la onda S, dentro del mismo complejo QRS. Es un indicador del tiempo de conducción intraventricular.




Figura 2. Ondas componentes y principales intervalos de la señal electrocardiográfica.

- El Intervalo QT. Corresponde al intervalo de tiempo entre el comienzo del complejo QRS y el final de la onda T, representando la duración de la sístole eléctrica. La relación entre el ritmo cardíaco y la duración de este intervalo viene dado en la tabla 1.

Tabla 1. Duración del intervalo QT

Ritmo cardiaco	Duración del QT (seg)
60	0.33 – 0.43
70	0.31 – 0.41
80	0.29 – 0.38
90	0.28 – 0.36
100	0.27 – 0.35
120	0.25 – 0.32

1.1.3 Derivaciones

Dependiendo de la posición sobre la superficie del cuerpo del paciente donde se coloquen los electrodos, se tendrán distintas derivaciones o pares de puntos. En resumen, estas derivaciones son:

- *Bipolares*. Los electrodos se colocan en las extremidades, derivaciones **I**, **II**, y **III**, registran, cada una, las diferencias en potencial entre dos miembros. En la base de datos del MIT se hace referencia a la derivación **MLII** ("*modified limb lead II*") la cual es una derivación bipolar modificada de la rama **II**, pero usando los electrodos en el pecho.
- *Unipolares*. De modo común, se usan en electrocardiografía clínica nueve derivaciones unipolares adicionales, o sea derivaciones que registran la diferencia de potencial entre un electrodo explorador y un electrodo indiferente; hay seis derivaciones torácicas unipolares (derivaciones precordiales), designadas **V1** a **V6**, y tres derivaciones de los miembros: **VR** (brazo derecho), **VL** (brazo izquierdo) y **VF** (pie izquierdo)
- *Aumentadas*. Variantes de las anteriores, son registros entre un miembro y los otros dos, designadas por la letra a (**aVR**, **aVL**, **aVF**.)

1.1.4 Patologías

En este apartado se describen solo las patologías con las cuales se trabajaron en este proyecto, así como sus manifestaciones en el ECG.

- *Taquicardia*. Corresponde a un ritmo cardíaco anormalmente alto. Puede ser supraventricular o auricular, y ventricular. Su aparición es debida a la formación de un circuito que permite el inicio de un ciclo continuo automantenido. La taquicardia por “reentrada” sí es debida a la formación de este circuito automantenido, pero existe otro posible mecanismo, la taquicardia por “automatismo”, en el que existe un foco de células que se despolarizan automáticamente por su cuenta, transmitiendo el impulso al resto.
- *Fibrilación*. Corresponde a un ritmo caótico, asociado con un funcionamiento no útil de las cámaras asociadas. Puede darse en la aurícula o en el ventrículo, siendo este último la causa de muerte en pacientes cardíacos.
- *Bloqueo AV*. Cuando el tejido no transmite el impulso de aurícula a ventrículo, el corazón puede parar completamente. Se debe sospechar cuando el músculo ventricular responde con un ritmo muy bajo, de unos 30 lpm o incluso menor. Estos latidos son de “escape”, pues al no llegarle impulso, el ventrículo termina por despolarizarse automáticamente, aunque sólo puede hacerlo muy lentamente.

1.1.4.1 Características Electrocardiográficas de las Arritmias

- **Ritmo Cardíaco Normal.** Este es el ritmo cardíaco presente en un corazón humano en condiciones normales, pero se debe tener en cuenta que puede cambiar según el estado físico y anímico de la persona.

Electrocardiograma:

- ❖ Onda P: No sobrepasa lo 0.08 seg de duración.
- ❖ Intervalo PR o PQ: Su duración en un adulto es de 0.12 a 0.20 seg.

- ❖ Complejo QRS: Normalmente debe durar de 0.04 a 0.10 seg, su amplitud varia según la derivación. La onda Q generalmente tiene un duración de 0.04 seg.
 - ❖ Intervalo QT: Varía con la frecuencia cardiaca, en un adulto no debe ser mayor a 0.44 seg, un QT prolongado predispone arritmias graves.
 - ❖ Onda T: Dura aproximadamente 0.20 seg.G
- **Bradicardia sinusal (*Sinus Bradycardia SBR*)**. El termino “bradicardia” significa disminución de la frecuencia cardiaca. Se caracteriza por presentar un ritmo completamente regular, pero más lento que el normal. La frecuencia cardiaca es inferior a 60 latidos por minuto, no bajando por lo común de 40.

En esa arritmia el estímulo comienza con el nódulo sinusal, pero con su automatismo disminuido, y sigue las vías normales de excitación cardiaca.

Ocurre por igual en sujetos con corazón sano como en determinadas condiciones fisiológicas y patológicas. Habitualmente se presenta en deportistas bien entrenados.

Electrocardiograma:

- ❖ Onda P tienen una morfología normal y se registran delante de cada QRS con un PR constante y mayor de 0.12 seg.
 - ❖ Segmento PQ normal y constante.
 - ❖ Intervalo QT normal o prolongado.
 - ❖ Frecuencia cardiaca menor de 60 latidos por minuto (*beat per minute*).
- **Taquicardia ventricular (*Ventricular Tachycardia VT*)**. Se considera la presencia de tres o más latidos ventriculares seguidos. Generalmente se debe a problemas isquémicos como la coronariopatía o infarto agudo del

miocardio. Casi siempre es un foco único el que se dispara repetitivamente o una extrasístole que se perpetua por reentrada.

Electrocardiograma:

- ❖ No hay onda P.
- ❖ Complejo QRS es ancho, habitualmente mayor de 0.12 seg.
- ❖ La onda T es opuesta al complejo QRS.
- ❖ Frecuencia ventricular oscila entre los 130 y los 200 latidos por minuto.

- **Taquicardias Supraventriculares (*Supraventricular Tachyarrhythmia SVTA*)**. También llamadas taquicardia paroxística auricular o la del nódulo AV. El termino “paroxística” significa que la frecuencia cardiaca suele acelerarse en forma de crisis que comienzan bruscamente y duran unos segundos, horas o son mucho más prolongadas. Esta arritmia suele aparecer en personas jóvenes y sanas.

En general, la *SVTA* alarma enormemente al paciente y puede causar debilidad durante los paroxismos (crisis), pero solo raramente producen daños permanentes.

Electrocardiograma:

- ❖ Intervalo RR regular.
- ❖ Complejo QRS y onda T usualmente normales
- ❖ Intervalo PR menor que 0.12 seg.
- ❖ La onda T puede estar invertida
- ❖ Las ondas P y T se superponen ó ausencia de la onda P.
- ❖ Frecuencia cardiaca mayor de 100 latidos por minuto.

- **Aleteo Auricular (*Flutter Atrial AFL*)**. Es una arritmia muy frecuente que casi siempre se asocia a una cardiopatía orgánica o hipertensión arterial. Se caracteriza por la ausencia de ondas P que son sustituidas por ondas F (en forma de diente de sierra).

En esta arritmia se presenta una frecuencia regular de descarga de la aurícula entre 200 y 300 veces por minuto por descarga de un foco ectópico. El impulso es conducido en grados variables a los ventrículos, por ejemplo por cada 2 latidos auriculares se conduce uno al ventrículo.

Electrocardiograma:

- ❖ Desaparecen las ondas P y en lugar de ellas aparecen las ondas F en forma de dientes de sierra.
- ❖ Complejo QRS estrechos.
- ❖ Frecuencia auricular entre 200 y 300 latidos por minuto (*bmp*) aprox.
- ❖ Frecuencia ventricular entre 100 y 150 latidos por minuto.

- **Fibrilación Auricular (*Atrial Fibrillation AFIB*).** Es una de las arritmias que más se presentan. Una causa de la presencia de esta arritmia es el aumento del tamaño de las aurículas que se produce como consecuencia de las lesiones valvulares del corazón que impiden a las aurículas vaciarse suficientemente en los ventrículos, o de una insuficiencia ventricular acompañada de un exceso de sangre en las aurículas. Ya que las aurículas no impulsan sangre durante esta arritmia, estas se vuelven inútiles como bombas de cebado para los ventrículos. A pesar de todo, la sangre atraviesa pasivamente las aurículas para entrar en los ventrículos, y la eficacia del bombeo ventricular desciende en un 20% a 30%.

Electrocardiograma:

- ❖ No hay onda P
- ❖ Complejo QRS normal
- ❖ Existencia de oscilaciones en la línea base del ECG, conocidas como ondas F.
- ❖ Intervalo R-R variable
- ❖ Frecuencia auricular mayor a 350 latidos por minuto (*bmp*).
- ❖ Frecuencia ventricular suele oscilar entre 90 y 150 latidos por minuto.

- **Contracciones Ventriculares Prematuras (PVC).** Esta alteración cardiaca es producida por la despolarización ventricular precoz. Algunas PVC son de origen bastante benigno y se deben a factores tales como el consumo de cigarrillos, de café, falta de sueño, algunas intoxicaciones leves e incluso a irritaciones de carácter emocional.

Electrocardiograma.

- ❖ El complejo QRS suele estar considerablemente prolongado mayor a 0.12 seg. y es de morfología extravagante.
- ❖ No hay onda P.
- ❖ Después de casi todas las PVC, la polaridad de la onda T es opuesta a la del complejo QRS.
- ❖ Si hay una pausa compensatoria después del Complejo Ventricular Prematuro (el intervalo R-R es más prolongado). Hay varios tipos de complejos (*PVC rhythm patterns*) entre otros:
 - **Bigeminismo (*Bigeminy, B*)** – PVC cada 2 latidos (a cada sístole normal le sigue una extrasístole).
 - **Trigeminismo (*Trigeminy, T*)** – PVC cada 3 latidos (por cada dos sístoles normales aparece una extrasístole).

1.2 Base de datos de las señales electrocardiográficas

La validación de cualquier tratamiento automatizado de señales electrocardiográficas, requiere su aplicación a un conjunto amplio de estas señales, las cuales además deberán cubrir el abanico más general posible de patologías, derivaciones, etc., correspondientes a situaciones reales.

Es por esta razón que se utilizó la base de datos del MIT (*Massachusetts Institute of Technology*) una de las principales fuentes de registros electrocardiográficos a nivel mundial, la cual dispone de un conjunto de señales suficientemente amplio para llevar a cabo pruebas muy representativas, además de contar con un formato de datos abierto y común a todas ellas, lo que reduce considerablemente el esfuerzo de desarrollo de aplicaciones. Estas van a ser las principales razones por lo que va a ser la fuente utilizada en los experimentos que validan los métodos propuestos en el presente trabajo. Sin embargo, a través del MIT se tiene acceso a registros de otras bases de datos, con lo cual todas las señales a utilizar se pueden obtener de la misma fuente. Con el paso del tiempo se han ido añadiendo registros pertenecientes a otras patologías, y de mayor duración, llegando incluso a registros de hasta 24h. Así, a través del MIT se tiene acceso a las siguientes bases de datos:

- **Base de datos de arritmias (*Arrhythmia Database*).** Contiene 48 fragmentos de 30 minutos correspondientes a registros ambulatorios de dos canales. La frecuencia de muestreo es de 360Hz, con 11 bits de resolución y un rango de 10mV. A través de *Physionet* se pueden obtener 25 de los 48 registros.
- **MIT-BIH Malignant Ventricular Arrhythmia Database.** Se encuentran disponibles 22 registros de media hora. A través de *Physionet* se puede obtener la totalidad de los registros.
- **MIT-BIH Atrial Fibrillation/Flutter Database.** Contiene 25 registros de 10 horas. Se pueden obtener 23 de los 25 registros a través de *Physionet*.
- **MIT-BIH Supraventricular Arrhythmia Database.** Esta base de datos incluye 78 registros de media hora. A través de *Physionet* se puede obtener la totalidad de los registros.
- **MIT-BIH Normal Sinus Rhythm Database.** A través de *Physionet* se puede obtener la totalidad de los registros.
- **La base de datos QT.** La base de datos QT fue diseñada a partir de la base de datos del MIT con el objetivo de evaluar algoritmos de detección de ondas en el electrocardiograma. Esta base de datos consiste en 105

fragmentos de 15 minutos de duración, provenientes de registros *Holter* de dos canales, elegidos por varios expertos con el objetivo de incluir una amplia variedad de complejos QRS y morfologías ST-T.

Una ventaja de trabajar con la base de datos del MIT es que las señales contienen anotaciones. Normalmente, cada complejo QRS, ha sido manualmente anotado por dos o más cardiólogos, trabajando de forma independiente.

Con las señales obtenidas a través de *Physionet* se dispone de las siguientes arritmias: Bradicardia Sinusal, Taquicardia Ventricular, Taquicardia Supraventricular, Flúter Auricular, Fibrilación Auricular, Bigeminismo Ventricular y Trigeminismo Ventricular.⁷

Se formo una base de datos de señales electrocardiográficas de distintas fuentes del MIT (*Massachusetts Institute of Technology*) principalmente de la *Arrhythmia Database* de la cual se descargo 25 de los 48 registros a través de la *web*⁸. De la misma manera se descargo las anotaciones de cada registro hechas por especialistas cardiólogos que hacen clasificaciones precisas de cada uno de los episodios. Luego se procedió a organizar los registros y anotaciones de acuerdo al tipo de derivación en archivos con extensión *.xls en los cuales quede comprendido toda la información (señal + anotación). Para aportar más flexibilidad a la base de datos se crearon nuevos registros tomando fragmentos de las señales originales haciendo una concatenación como la continuación de otra señal.

En este proyecto se ha desarrollado una serie de aplicaciones en LabVIEW para la visualización de los resultados. También se ha utilizado el paquete de software matemático Matlab en la implementación y entrenamiento de la Red Neuronal para el reconocimiento de los patrones de las diferentes tipos de arritmias.

⁷ Cada registro va a quedar almacenado en el disco duro con extensiones del tipo hoja de calculo (*.xls) o del tipo texto (*.txt), compatibles con Labview, Matlab y muchos lenguajes de análisis digital.

⁸ www.physionet.org

1.3 Clasificación de las señales ECG

Para poder hacer una clasificación de las señales ECG, se tiene que hacer previamente un procesamiento de éstas, parametrizando cada señal mediante un conjunto, que en este proyecto se decidió sería de 14 valores que corresponden a sus características temporales y frecuenciales.

Estas características son las siguientes:

➤ Características temporales:

- Cruces por cero,
- 4 primeros coeficientes del modelo AR (auto correlación) orden 16 de predicción lineal (LPC),⁹
- Energía (mV^2) de la señal ECG en el dominio del tiempo (Teorema de

Parseval),¹⁰ el cual se calcula con la ecuación: $\sum_{n=0}^{N-1} |X[n]|^2$

- Valor rms (mV) de la señal ECG,
- Media (mV),
- Periodo (ms) comprendido entre dos o tres picos R (equivalente al intervalo R-R su valor varía con la frecuencia cardiaca).

➤ Características frecuenciales:

Calculadas a partir de la FFT

- Ancho de banda al 95% de la energía,
- Desviación estándar,
- Frecuencia fundamental,

⁹ En el anexo L, se encuentra la teoría de análisis de predicción lineal

¹⁰ En el anexo L, se encuentra el Teorema de Parseval

- THD (*Total Harmonica Distorsion*), es definido como la relación de la suma RMS de la amplitud de los armónicos del tono fundamental. En términos computacionales THD es un porcentaje.

Calculadas a partir de la PSD (*Power Spectral Density*)

- Varianza

Se aclara que podría presentarse confusión en cuanto al número de parámetros ya que a simple vista se enumeran 11, pero hay que tener en cuenta que no es un solo coeficiente de predicción lineal sino 4, entonces serian 14 patrones en total.

A continuación se presentan las características en tiempo y en frecuencia del ritmo cardiaco normal y de siete arritmias para establecer los parámetros que se deben tener en cuenta en la identificación.

1.3.1 Ritmo Cardiaco Normal (RCN). Es este el ritmo cardiaco presente en un hombre de 69 años en condiciones normales tomado de la derivación MLII, y su variación del ritmo cardiaco esta entre 70-98 latidos por minuto (bpm).¹¹




Figura 3. Ritmo cardiaco normal (Normal Sinus Rhythm)

|

¹¹ Registro 100: (MLII , V1; male, age 69) del MIT-BIH Arrhythmia Database , www.physionet.org

Se observa en la figura 3 ocho ciclos cardiacos, con una duración de aproximadamente 7 seg; otras características temporales de esta señal se observan en la tabla 2.

Tabla 2. Características temporales del Ritmo Cardíaco Normal

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
108	0,081	0,051	7,001	82,561

Teniendo en cuenta los cálculos de los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal (LPC), se tienen los siguientes resultados.

Tabla 3. Coeficientes de predicción lineal del Ritmo Cardíaco Normal

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-2,122	1,312	0,173	-0,379

Para obtener características frecuenciales de la señal, se halla el espectro basado en el cálculo de la transformada discreta de Fourier (FFT) de la señal. Si la señal fuera perfectamente periódica aparecerían pulsos en el espectro localizados en múltiplos enteros de la frecuencia fundamental de la señal. En este caso no es perfectamente periódica aunque se puede apreciar un efecto similar al descrito. En la figura 4 se puede observar parte del espectro obtenido de la forma descrita.




Figura 4. Espectro en frecuencia del Ritmo Cardíaco Normal

En la figura 4 puede apreciarse que existe máximo en el espectro a una frecuencia de 1.12 Hz, que podría ser la frecuencia fundamental pero la asociamos a una frecuencia de resonancia donde existe un máximo relativo debido a que estas señales no son del todo periódicas, se tomó como referencia las frecuencias asociadas donde existirá una resonancia. Otras características frecuenciales de esta señal se observan en la siguiente tabla.

Tabla 4. Características del espectro frecuencial del Ritmo Cardíaco Normal

Frecuencia Fundamental (Hz)	Ancho de banda 95% E (Hz)	Desviación Estándar	Varianza	THD
1,129	13,829	9,136	22,112	1,433

En la tabla 4 se muestra que el ancho de banda donde esta el 95 % de la energía es de 13.82 Hz, la desviación estándar es de 9.136, la varianza de 22.112 y el THD es de 1.433

Se observa en la figura 5 otra señal de ritmo cardíaco normal perteneciente a otro paciente¹². Se trata de seguir la misma tendencia en cuanto a los parámetros como se puede ver en la tabla 5.

Tabla 5. Características temporales y frecuenciales del Ritmo Cardíaco Normal

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la Señal (mV) ²
94	-0,026	0,214	7,928	45,574
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-1,511	1,376	-0,845	0,276	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E (Hz)	Desviación Estándar	Varianza	THD
1,009	9,965	3,960	28,121	1,042

¹² Registro: 16483 del *MIT-BIH Normal Sinus Rhythm Database*, www.physionet.org



Figura 5. Ritmo cardiaco normal y su Espectro frecuencial

En la tabla 6 se presentan los parámetros temporales y frecuenciales de 14 diferentes señales de ritmo cardiaco normal. Aunque puede existir dispersión en los patrones temporales y frecuenciales, todas las señales tienden a tener una frecuencia máxima en su espectro cercana a 1 Hz (ya que su rango va de 1,021 hasta 1,596 Hz).

Tabla 6. Patrones pertenecientes a otras 14 señales de Ritmo Cardíaco Normal

Parámetros	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
Cruces por cero	126	139	166	148	106	93	95	98	120	124	117	109	188	95
1-4 Coeficientes LPC	-1,675	-1,457	-0,777	-2,058	-2,112	-2,141	-1,775	-1,35	-1,623	-1,798	-2,12	-2,147	-2,023	-2,12
2-4 Coeficientes LPC	1,557	0,285	0,357	1,128	1,293	1,339	1,817	0,661	0,496	0,572	1,297	1,363	0,936	1,133
3-4 Coeficientes LPC	-0,788	0,226	-0,029	0,335	0,128	0,162	-1,147	0,062	0,389	0,466	0,23	0,094	0,39	0,411
4-4 Coeficientes LPC	0,032	0,024	-0,103	-0,375	-0,251	-0,318	0,333	-0,036	-0,107	-0,116	-0,449	-0,241	-0,208	-0,479
Frecuencia fundamental (Hz)	1,226	1,596	1,535	1,132	1,142	1,131	1,106	1,286	1,021	1,149	1,128	1,142	1,492	1,172
Ancho de Banda del 95% energía (Hz)	20,846	25,999	20,921	22,359	21,049	23,883	16,408	16,563	11,524	8,235	7,733	6,362	5,541	6,797
Desviación Estándar (Frec)	19,079	11,352	8,189	9,925	11,899	9,985	22,353	21,837	9,663	14,779	10,988	11,579	15,315	22,972
Varianza (Frec)	6,762	3,655	6,299	24,001	17,826	20,784	14,966	20,789	19,593	3,429	15,574	12,895	4,075	19,587
Energía (mV) ²	25,916	60,52	63,626	70,243	62,284	70,527	25,673	263,538	30,566	50,28	62,305	61,883	427,587	307,98
Media (mV)	-0,01	-0,006	-0,033	0,011	-0,019	-0,039	-0,02	-0,13	0,034	-0,011	-0,034	-0,009	-0,018	-0,023
THD	1,682	0,626	1,126	1,491	1,595	1,117	1,705	0,503	0,851	1,163	1,759	1,642	1,145	1,037
rms (mV)	0,193	0,167	0,313	0,173	0,175	0,173	0,195	0,582	0,132	0,17	0,174	0,174	0,435	0,469
Intervalo R-R (seg)	4,893	4,385	5,21	7,066	6,129	7,076	5,424	6,219	6,855	5,222	6,208	6,13	4,692	4,266

1.3.2 Bradicardia Sinusal (SBR). Este es el registro electrocardiográfico tomado de la derivación MLII, presente en una mujer de 76 años, y su variación del ritmo cardiaco esta entre 24-28 latidos por minuto (bpm).¹³

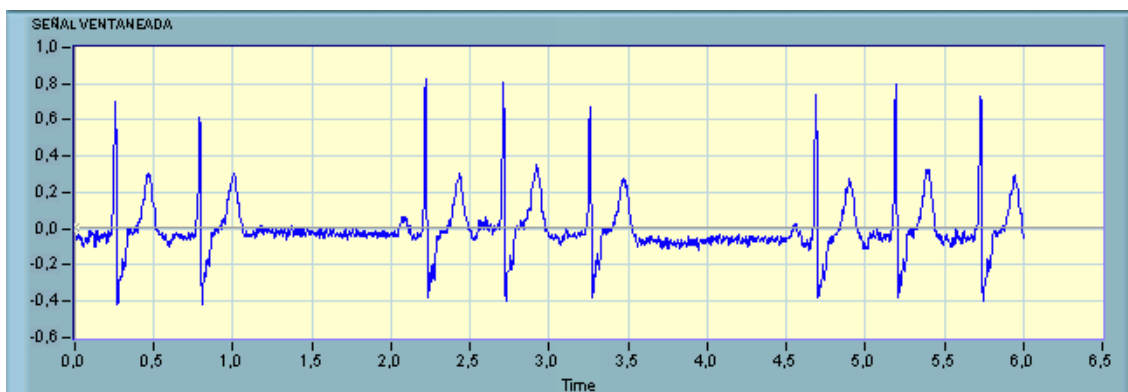


Figura 6. Bradicardia Sinusal (*Sinus Bradycardia*)

Se observa en la figura anterior ocho ciclos cardiacos, con una duración aproximadamente de 6,002 seg; otras características temporales de esta señal se observan en la siguiente tabla.

Tabla 7. Características temporales de la Bradicardia Sinusal

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
124	-0,029	0,141	6,002	59,451

Teniendo en cuenta los cálculos de los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal (LPC), se tienen los siguientes resultados.

Tabla 8. Coeficientes de predicción lineal de la Bradicardia Sinusal

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-1,770	0,451	0,545	0,056

¹³ Registro 232: (MLII, V1; female, age 76) del MIT-BIH Arrhythmia Database, www.physionet.org




Figura 7. Espectro en frecuencia de la Bradicardia Sinusal

En la figura 7 se puede observar parte del espectro de la Bradicardia Sinusal (*Sinus Bradycardia*), donde existe un máximo en el espectro a una frecuencia de 2,512 Hz. Otras características frecuenciales de esta señal se observan en la siguiente tabla.

Tabla 9. Características del espectro frecuencial de la Bradicardia Sinusal

Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
2,512	8,164	8,907	13,333	0,370

Puede apreciarse que el ancho de banda donde está el 95 % de la energía es de 8,164 Hz, la desviación estándar es de 8,907, la varianza de 13,33 y el THD que es de 0,370

Tabla 10. Características temporales y frecuenciales de la SBR

Cruces por cero	Media	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
127	-0,002	0,161	7,245	61,944
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-1,811	0,469	0,584	0,064	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
2,542	6,073	10,078	27,852	1,171




Figura 8. Bradicardia Sinusal y su Espectro frecuencial

Se observa en la figura 8 otra señal ventaneada de la Bradicardia Sinusal perteneciente al registro electrocardiográfico de la misma paciente. Se trata de seguir la misma tendencia en cuanto a los parámetros como se puede ver en la tabla 10.

En la tabla 11 se presentan los respectivos parámetros temporales y frecuenciales de 14 diferentes señales de Bradicardia Sinusal. Se puede apreciar que todas las señales tienden a tener una frecuencia máxima en su espectro cercana a 2.56 Hz (ya que su rango va de 2,465 hasta 2,7 Hz); otra particularidad es que su ancho de banda del 95% de la energía esta en un rango que oscila entre 8,052 y 10,102; finalmente su valor rms (mV) se encuentra en unos valores que oscilan entre 0,113 y 0,169.

Tabla 11. Patrones pertenecientes a otras 14 señales de Bradicardia Sinusal

Parámetros	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
Cruces por cero	102	162	135	123	120	133	116	126	152	158	161	160	101	92
1-4 Coeficientes LPC	-1,812	-1,713	-1,64	-1,605	-1,739	-1,513	-1,48	-1,553	-1,509	-1,797	-1,619	-1,518	-1,845	-1,668
2-4 Coeficientes LPC	0,489	0,34	0,314	0,29	0,492	0,042	0,098	0,25	0,114	0,629	0,379	0,314	0,522	0,38
3-4 Coeficientes LPC	0,6	0,565	0,47	0,394	0,396	0,429	0,376	0,373	0,372	0,429	0,389	0,28	0,621	0,426
4-4 Coeficientes LPC	-0,005	0,12	0,092	0,183	0,124	0,264	0,183	0,109	0,198	-0,004	0,064	0,098	-0,017	0,078
Frecuencia Fundamental (Hz)	2,512	2,61	2,711	2,468	2,612	2,465	2,533	2,526	2,545	2,634	2,7	2,588	2,542	2,497
Ancho de Banda del 95% energía (Hz)	8,707	8,555	9,419	8,639	8,816	8,052	9,119	10,102	8,625	8,781	9,553	8,972	8,525	8,488
Desviación Estándar (Frec)	13,245	6,744	4,612	4,318	9,122	11,008	10,346	9,131	9,129	11,391	12,822	10,985	15,36	10,757
Varianza (Frec)	10,141	8,117	15,635	3,868	23,212	29,201	27,351	29,501	31,284	3,393	18,061	3,236	3,547	29,538
Energía (mV) ²	48,247	42,806	33,62	34,378	44,126	43,706	36,858	52,362	51,186	48,009	42,021	42,476	62,377	50,505
Media (mV)	-0,014	0,022	0,022	-0,018	-0,014	0,02	0,026	0,026	-0,016	0,025	-0,008	-0,028	0,003	0,03
THD	0,705	0,639	0,678	0,541	0,432	0,32	0,666	0,659	0,671	0,59	0,556	0,602	0,551	0,879
rms (mV)	0,157	0,137	0,12	0,113	0,147	0,148	0,137	0,148	0,147	0,159	0,162	0,148	0,169	0,159
Intervalo R-R (seg)	5,972	6,896	7,007	8,103	6,125	6,085	5,922	7,127	7,073	5,694	4,815	5,796	6,688	6,008

1.3.3 Fibrilación Auricular (AFIB). Este es el registro electrocardiográfico tomado de la derivación MLII, presente en una mujer de 89 años, y su variación del ritmo cardiaco está entre 63-158 latidos por minuto (bpm).¹⁴

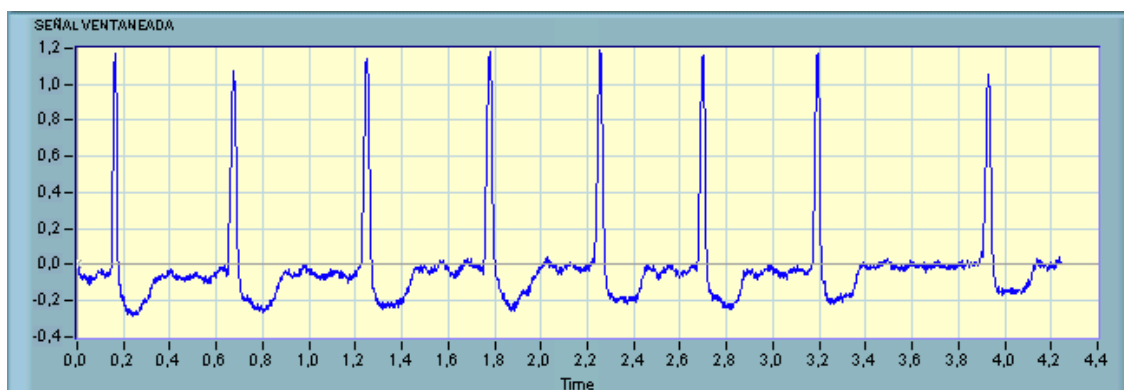


Figura 9. Fibrilación Auricular (*Atrial Fibrillation*)

Se observa en la figura anterior ocho ciclos cardiacos de una Fibrilación Auricular, con una duración aproximada de 4,243 seg (duración por ciclo 0,53 seg equivalente a un ritmo cardiaco de 113 bpm); otras características temporales de esta señal se observan en la tabla siguiente.

Tabla 12. Características temporales de la Fibrilación Auricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
137	-0,047	0,230	4,243	113,495

Teniendo en cuenta los cálculos de los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal (LPC), se tienen los siguientes resultados.

Tabla 13. Coeficientes de predicción lineal de la Fibrilación Auricular

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-1,833	0,703	0,381	-0,291

¹⁴ Registro 210: (MLII, V1; male, age 89) del MIT-BIH *Arrhythmia Database*, www.physionet.org




Figura 10. Espectro en frecuencia de la Fibrilación Auricular

En la figura 10 se puede observar parte del espectro de la Fibrilación Auricular (*Atrial Fibrillation*), donde existe un máximo en el espectro a una frecuencia de 4,242 Hz. Otras características frecuenciales de esta señal se observan en la siguiente tabla.

Tabla 14. Características del espectro frecuencial de la Fibrilación Auricular

Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
4,242	17,264	25,611	6,752	0,403

Puede apreciarse que el ancho de banda donde esta el 95 % de la energía es de 17,264 Hz, la desviación estándar es de 25,611, la varianza de 6,752 y el THD que es de 0,403

Se observa en la figura 11 ocho ciclos (señal ventaneada) de *Atrial Fibrillation* (perteneciente a un registro electrocardiográfico de MIT-BIH *Atrial Fibrillation/Flutter Database*), con una duración por ciclo de 0,579 seg, que equivale a una frecuencia cardiaca de 103 bmp. Se presenta en la tabla 15 todos los parámetros de frecuencia y tiempo.



Figura 11. Fibrilación Auricular y su Espectro frecuencial

Tabla 15. Características temporales y frecuenciales de la Fibrilación Auricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
224	-0,010	0,292	4,637	101,126
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-1,986	1,454	-0,320	-0,208	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
4,098	31,488	4,127	11,701	0,626

En la tabla 16 se presentan los respectivos parámetros temporales y frecuenciales de 14 diferentes señales de Fibrilación Auricular. Se puede apreciar que todas las señales tienden a tener una frecuencia máxima en su espectro cercana a 4,218 Hz (ya que su rango va de 3,99 hasta 4,56 Hz); otra particularidad es que su ancho de banda del 95% de la energía esta en un rango que oscila entre 11,05 y 31,48; finalmente su valor rms (mV) se encuentra en unos valores que oscilan entre 0,104 y 0,311.

Tabla 16. Patrones pertenecientes a otras 14 señales de Fibrilación Auricular (*Atrial Fibrillation*)

Parámetros	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
Cruces por cero	111	121	59	250	58	79	66	125	224	73	59	99	67	44
1-4 Coeficientes LPC	-1,986	-1,991	-1,465	-1,433	-1,891	-1,857	-1,628	-1,602	-1,986	-1,904	-1,61	-1,549	-1,599	-1,49
2-4 Coeficientes LPC	1,172	1,139	0,305	0,262	1,23	1,097	0,808	0,819	1,454	1,274	0,411	0,416	0,406	0,282
3-4 Coeficientes LPC	0,109	0,209	0,103	0,001	-0,524	-0,396	-0,016	-0,032	-0,32	-0,208	0,344	0,285	0,314	0,464
4-4 Coeficientes LPC	-0,356	-0,391	-0,018	0,104	0,103	0,028	-0,135	-0,114	-0,208	-0,169	-0,104	-0,168	-0,107	-0,494
Frecuencia fundamental (Hz)	4,16	4,151	4,063	4,177	4,277	4,097	4,561	4,258	4,098	4,526	3,99	4,115	4,035	4,555
Ancho de Banda del 95% energía (Hz)	11,051	16,144	20,898	16,185	20,824	17,086	25,382	26,877	31,488	28,287	15,212	12,407	13,055	18,634
Desviación Estándar (Frec)	17,313	19,03	21,711	6,598	3,313	20,369	4,195	5,298	4,127	6,16	14,749	11,066	18,646	5,933
Varianza (Frec)	3,506	6,88	19,348	6,639	8,007	5,718	9,931	25,76	11,701	17,488	6,008	4,067	4,453	24,535
Energía (mV) ²	58,568	68,312	5,711	15,841	73,266	66,043	118,31	88,715	101,126	87,519	27,907	21,498	36,444	85,002
Media (mV)	-0,002	-0,012	0,028	0,013	-0,03	-0,025	-0,13	-0,045	-0,01	-0,105	0,006	0	0,02	-0,048
THD	0,547	0,773	0,564	0,468	0,641	0,653	0,389	0,648	0,626	1,434	0,516	0,566	0,331	0,5
rms (mV)	0,172	0,175	0,114	0,104	0,241	0,206	0,303	0,304	0,292	0,311	0,146	0,123	0,159	0,266
Intervalo R-R (seg)	7,69	8,671	1,722	5,746	4,91	6,102	5,043	3,758	4,637	3,535	4,01	4,131	4,213	2,415

1.3.4 Trigemismo Ventricular (*Ventricular Trigeminy, T*). Este el registro electrocardiográfico tomado de la derivación MLII, presente en un hombre de 51 años , y su variación del ritmo cardiaco esta entre 71-87 latidos por minuto (bmp).¹⁵




Figura 12. Trigemismo Ventricular

Se observa en la figura anterior ocho ciclos cardiacos, con una duración aproximadamente de 6,226 seg, que equivale a una duración por ciclo de 0,778 seg, esto es una frecuencia cardiaca de 77 bmp. Otras características temporales de esta señal se observan en la tabla 17.

Tabla 17. Características temporales de Trigemismo Ventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
60	-0,112	0,642	5,031	370,268

Teniendo en cuenta los cálculos de los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal (LPC), se tienen los siguientes resultados.

Tabla 18. Coeficientes de predicción lineal de Trigemismo Ventricular

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-1,785	0,607	0,336	-0,082

¹⁵ Registro: 119 (MLII , V1; female, age 51) del MIT-BIH Arrhythmia Database , www.physionet.org




Figura 13. Espectro en frecuencia del Trigemismo Ventricular

En la figura 13 se puede observar parte del espectro del Trigemismo Ventricular, donde existe un máximo en el espectro a una frecuencia de 2,409 Hz. Otras características frecuenciales de esta señal se observan en la tabla 19.

Tabla 19. Características del espectro frecuencial de Trigemismo Ventricular

Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
2,409	11,563	7,58	4,447	0,484

Puede apreciarse que el ancho de banda donde esta el 95 % de la energía es de 11,563 Hz, la desviación estándar es de 7,58, la varianza de 4,447 y el THD es de 0,484.

En la figura 14 se observa un Trigemismo Ventricular (señal ventaneada) perteneciente a un registro electrocardiográfico MIT-BIH *Arrhythmia Database*¹⁶ con una duración por ciclo de 0,903 seg, esto es una frecuencia cardiaca de 66 latidos por minuto (bpm). Se trata de seguir la misma tendencia en cuanto a los parámetros como se puede ver en la tabla 20.

¹⁶ Registro: 214 (MLII , V1; male, age 53) del MIT-BIH *Arrhythmia Database* , www.physionet.org



Figura 14. Señal Trigemino Ventricular y su Espectro frecuencial

Tabla 20. Características temporales y frecuenciales de la señal Trigemino Ventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
145	0,002	0,363	7,227	311,879
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-1,876	0,682	0,469	-0,178	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
2,214	9,133	7,812	23,108	0,387

En la tabla 21 se presentan los respectivos parámetros temporales y frecuenciales de 14 diferentes señales de Trigemino Ventricular. Se puede apreciar que todas las señales tienden a tener una frecuencia máxima en su espectro cercana a 2,4 Hz (ya que su rango va de 2,32 hasta 2,55 Hz); otra particularidad es que su energía está en un rango que oscila entre 215 y 731,49.

Tabla 21. Patrones pertenecientes a otras 14 señales de Trigemismo Ventricular

Parámetros	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
Cruces por cero	118	126	39	20	14	16	81	20	20	10	22	20	10	24
1-4 Coeficientes LPC	-1,897	-1,889	-2,087	-1,785	-1,785	-2,035	-1,877	-1,867	-1,823	-1,942	-1,874	-2,11	-1,958	-2,099
2-4 Coeficientes LPC	0,844	0,827	1,048	0,607	0,659	1,116	0,815	0,831	0,708	0,982	0,785	1,1	0,939	1,136
3-4 Coeficientes LPC	0,254	0,248	0,383	0,336	0,272	0,14	0,26	0,195	0,28	0,121	0,288	0,402	0,228	0,398
4-4 Coeficientes LPC	-0,128	-0,093	-0,354	-0,082	-0,097	-0,28	-0,132	-0,177	-0,121	-0,206	-0,162	-0,274	-0,164	-0,437
Frecuencia fundamental (Hz)	2,493	2,469	2,4	2,409	2,426	2,421	2,559	2,368	2,388	2,326	2,387	2,378	2,322	2,326
Ancho de Banda del 95% energía (Hz)	2,16	5,401	4,349	11,563	7,939	6,255	4,653	8,525	7,802	7,85	7,864	8,719	8,417	14,536
Desviación Estándar (Frec)	10,723	10,888	17,648	7,58	12,623	13,995	11,168	8,779	12,758	25,324	12,343	3,235	26,198	24,357
Varianza (Frec)	5,06	7,783	26,59	4,447	5,019	11,833	12,077	16,693	3,749	14,524	6,34	5,627	17,082	7,738
Energía (mV) ²	316,864	371,388	731,485	299,682	310,313	390,646	234,442	356,292	421,991	281,064	499,96	280,843	267,025	215,014
Media (mV)	-0,025	-0,02	0,03	-0,133	-0,266	-0,306	-0,03	-0,2	-0,276	-0,301	-0,276	-0,09	-0,281	-0,045
THD	0,28	0,412	0,546	0,484	0,554	0,424	0,66	0,517	0,443	0,517	0,382	0,426	0,658	0,822
rms (mV)	0,393	0,41	0,567	0,379	0,452	0,486	0,4	0,41	0,448	0,499	0,458	0,543	0,481	0,498
Intervalo R-R (seg)	6,018	6,48	6,668	6,226	4,534	4,956	4,298	6,334	6,281	3,439	7,121	3,784	3,445	3,44

1.3.5 Bigeminismo Ventricular (*Ventricular Bigeminy, B*). Este es el registro electrocardiográfico tomado de la derivación MLII, presente en un hombre de 57 años, y su variación del ritmo cardiaco está entre 52-91 latidos por minuto (bpm)¹⁷.




Figura 15. Bigeminismo Ventricular

Se observa en la figura 15, ocho ciclos cardiacos con una duración aproximadamente de 5,091 seg; en la tabla 22 se puede apreciar otras características temporales de esta señal.

Tabla 22. Características temporales de Bigeminismo Ventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
32	-0,086	0,611	5,091	138,403

En la tabla 23 se presentan los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal para la señal de la figura 15.

Tabla 23. Coeficientes de predicción lineal de Bigeminismo Ventricular

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-2,016	0,730	0,521	0,030

¹⁷ Registro 233: (MLII, V1; male, age 57) del MIT-BIH Arrhythmia Database, www.physionet.org




Figura 16. Espectro en frecuencia del Bigeminismo Ventricular

En la figura 16 se puede apreciar parte del espectro de Bigeminismo Ventricular, donde existe un máximo en el espectro a una frecuencia de 2,169 Hz. Otras características frecuenciales de esta señal se observan en la tabla 24.

Tabla 24. Características del espectro frecuencial de Bigeminismo Ventricular

Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
2,169	9,398	9,865	12,638	0,645

Puede apreciarse que el ancho de banda donde esta el 95 % de la energía es de 9,398 Hz, la desviación estándar es de 9,865, la varianza de 12,638 y el THD es de 0,645.

Se observa en la figura 17 otra señal¹⁸ ventaneada de Bigeminismo Ventricular (perteneciente a un registro electrocardiográfico del QT *database*) de ocho ciclos, con una duración por ciclo de 0,699 equivalente a una frecuencia cardiaca de 85 bmp. En la tabla 25 se presenta la totalidad de los parámetros.

En la tabla 26 se presentan los respectivos parámetros temporales y frecuenciales de 14 diferentes señales de Bigeminismo Ventricular. Se puede apreciar que todas las señales tienden a tener una frecuencia máxima en su

¹⁸ Registro sel223 del QT *Database*, www.physionet.org

espectro cercana a 2,14 Hz (ya que su rango va de 2,104 hasta 2,194 Hz); otra particularidad es que su ancho de banda del 95% de la energía está en valores que oscilan entre 10,137 y 12,651 Hz; podría mencionarse que otro parámetro frecuencial como la desviación estándar (calculada a partir de la FFT) esta en un rango que oscila entre 9,37 y 14,67; y por último la energía de la señal esta en un rango que oscila entre 104,63 y 149,26.



Figura 17. Señal Bigeminismo Ventricular y su Espectro frecuencial

Tabla 25. Características temporales y frecuenciales de Bigeminismo Ventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
56	-0,034	0,341	5,596	161,291
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-1,848	0,651	0,539	-0,156	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
2,145	9,293	11,738	10,825	0,890

Tabla 26. Patrones pertenecientes a otras 14 señales de Bigeminismo Ventricular

Parámetros	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
Cruces por cero	26	45	67	35	60	39	44	44	35	42	28	50	50	32
1-4 Coeficientes LPC	-2,048	-2,128	-1,688	-1,714	-1,81	-1,817	-1,927	-1,874	-1,983	-2,232	-1,705	-1,975	-2,207	-2,011
2-4 Coeficientes LPC	1,069	1,279	0,391	0,387	0,633	0,639	0,818	0,757	0,886	1,376	0,498	0,975	1,385	0,96
3-4 Coeficientes LPC	0,401	0,25	0,54	0,558	0,497	0,479	0,54	0,49	0,523	0,389	0,408	0,318	0,26	0,531
4-4 Coeficientes LPC	-0,359	-0,43	-0,011	0,104	-0,138	-0,138	-0,338	-0,27	-0,282	-0,559	0,013	-0,221	-0,448	-0,471
Frecuencia Fundamental (Hz)	2,122	2,104	2,14	2,177	2,144	2,138	2,16	2,194	2,134	2,11	2,178	2,144	2,144	2,167
Ancho de Banda del 95% energía (Hz)	10,137	11,781	11,865	11,611	11,147	12,651	11,194	11,367	11,855	11,252	11,825	11,435	11,435	11,557
Desviación Estándar (Frec)	10,415	11,787	10,049	14,672	10,838	10,22	9,37	9,689	12,051	12,622	14,151	14,098	14,135	14,152
Varianza (Frec)	14,133	5,623	30,58	4,621	3,689	7,911	28,554	3,285	21,41	21,287	13,142	4,492	4,541	3,83
Energía (mV) ²	116,848	147,768	149,264	124,489	139,742	122,824	134,792	136,238	126,479	121,111	104,632	123,647	123,789	125,432
Media (mV)	-0,086	-0,03	-0,01	-0,026	-0,024	-0,034	-0,016	-0,024	-0,014	-0,054	-0,064	-0,029	-0,026	0,021
THD	0,869	1,119	1,13	1,092	0,706	0,56	0,821	0,814	0,862	1,171	0,898	0,974	0,974	1,065
rms (mV)	0,333	0,353	0,341	0,346	0,347	0,34	0,327	0,328	0,348	0,338	0,359	0,344	0,345	0,349
Intervalo R-R (seg)	4,242	4,753	5,141	4,134	4,665	4,209	5,092	5,015	4,218	4,266	3,214	4,198	4,198	4,153

1.3.6 Taquicardia Ventricular (*Ventricular Tachycardia, VT*). Este el registro electrocardiográfico tomado de la derivación MLII, presente en un hombre de 81 años , y su variación del ritmo cardiaco esta entre 174-177 latidos por minuto (bpm)¹⁹.




Figura 18. Taquicardia Ventricular

Se observa en la figura 18, ocho ciclos cardiacos con una duración de aproximadamente 3,929 seg. La taquicardia ventricular aparece en el cuarto y quinto ciclo de esta señal ventaneada, con una duración de 0,7 seg, que equivale a una duración por ciclo de 0.35 seg, equivalente a 171 bpm. En la tabla 27 se puede apreciar otras características temporales de esta señal.

Tabla 27. Características temporales de Taquicardia Ventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
34	-0,095	0,383	3,929	191,697

En la tabla 28 se presentan los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal para la señal de la figura 18.

Tabla. 28. Coeficientes de predicción lineal de Taquicardia Ventricular

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-1,992	0,854	0,455	-0,230

¹⁹ Registro 215: (MLII , V1; male, age 81) del MIT-BIH *Arrhythmia Database* , www.physionet.org

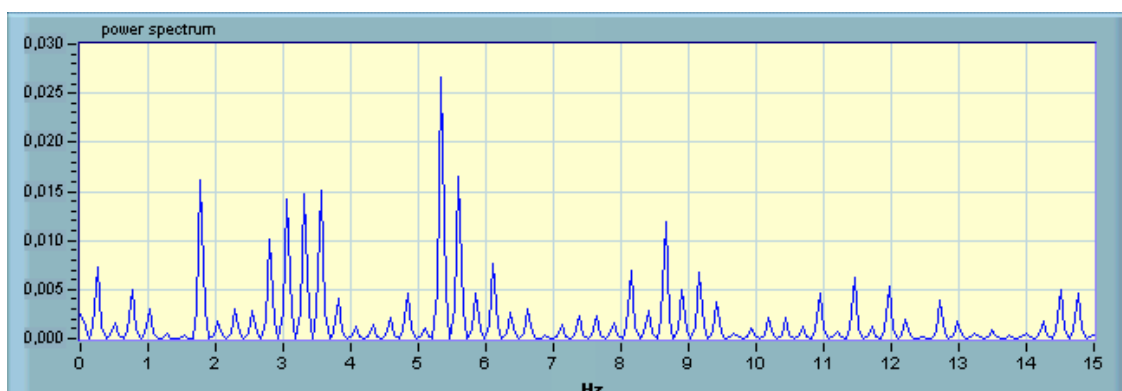


Figura 19. Espectro en frecuencia de Taquicardia Ventricular

En la figura 19 se puede apreciar parte del espectro de Taquicardia Ventricular, donde existe un máximo en el espectro a una frecuencia de 5,345 Hz. Otras características frecuenciales de esta señal se observan en la siguiente tabla.

Tabla 29. Características del espectro frecuencial de Taquicardia Ventricular

Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
5,345	14,508	10,474	21,237	0,270

Puede apreciarse que el ancho de banda donde esta el 95 % de la energía (calculadas a partir de la FFT) es de 14,50 Hz; la desviación estándar es de 10,47; la varianza (calculadas a partir de la PSD) es de 21,23 y el THD es de 0,270.

Podemos observar en la figura 20 otra señal²⁰ ventaneada de Taquicardia Ventricular (perteneciente a un registro electrocardiográfico del QT *database*) de ocho ciclos; con una duración por ciclo de 0,553 seg equivalente a una frecuencia cardiaca de 108 latidos por minuto. Se pueden ver todos los parámetros de tiempo y frecuencia en la tabla 30.

En la tabla 31 se presentan los respectivos parámetros temporales y frecuenciales de 14 diferentes señales de Taquicardia Ventricular. Se puede apreciar que todas las señales tienden a tener una frecuencia máxima en su

²⁰ Registro sel223 del QT *Database*, www.physionet.org

espectro cercana a 5,3 Hz (ya que su rango va de 5,25 hasta 5,61 Hz); otra particularidad es que su ancho de banda del 95% de la energía esta en valores que oscilan entre 10,59 y 14,5 Hz; podría mencionarse que otro parámetro frecuencial como la desviación estándar esta en un rango que oscila entre 7,23 y 20,15; la energía de la señal esta en un rango que oscila entre 92,38 y 191,7 Hz .




Figura 20. Señal Taquicardia Ventricular y su Espectro frecuencial

Tabla 30. Características temporales y frecuenciales de Taquicardia Ventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
16	-0,055	-0,049	4,426	147,754
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-2,084	1,107	0,265	-0,263	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
5,276	14,559	6,17	4,302	0,339

Tabla 31. Patrones pertenecientes a otras 14 señales de Taquicardia Ventricular

Parámetros	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
Cruces por cero	46	46	48	46	32	30	56	56	56	31	24	34	24	26
1-4 Coeficientes LPC	-2,092	-2,076	-2,084	-2,093	-2,071	-1,914	-2,107	-2,113	-2,105	-2,135	-2,305	-2,258	-2,305	-2,027
2-4 Coeficientes LPC	1,124	1,097	1,102	1,124	1,082	0,87	1,145	1,182	1,183	1,194	1,827	1,718	1,827	0,982
3-4 Coeficientes LPC	0,257	0,27	0,287	0,265	0,278	0,203	0,258	0,231	0,202	0,251	-0,492	-0,416	-0,492	0,328
4-4 Coeficientes LPC	-0,249	-0,274	-0,288	-0,266	-0,289	-0,078	-0,268	-0,289	-0,267	-0,318	-0,128	-0,127	-0,128	-0,283
Frecuencia Fundamental (Hz)	5,25	5,254	5,268	5,272	5,268	5,337	5,614	5,258	5,258	5,272	5,448	5,345	5,448	5,529
Ancho de Banda del 95% energía (Hz)	12,157	12,167	12,199	12,209	12,966	12,008	12,351	11,949	11,949	10,95	13,801	14,508	13,801	10,598
Desviación Estándar (Frec)	9,79	8,8	8,091	8,74	15,82	17,979	9,734	8,071	7,23	19,833	18,057	9,387	20,151	18,029
Varianza (Frec)	20,862	4,303	7,242	3,853	5,544	4,438	16,503	24,024	4,686	7,174	19,113	4,152	9,779	5,589
Energía (mV) ²	136,88	136,85	138,59	136,88	111,71	92,38	148,39	147,76	147,75	120,49	172,26	191,69	172,26	101,73
Media (mV)	-0,055	-0,055	-0,055	-0,055	-0,055	-0,035	0,022	-0,05	-0,05	0,022	-0,1	-0,095	-0,1	-0,04
THD	0,548	0,55	0,538	0,545	0,399	0,671	0,426	0,569	0,569	0,678	0,444	0,27	0,444	0,515
rms (mV)	0,337	0,337	0,339	0,337	0,369	0,351	0,349	0,326	0,326	0,386	0,434	0,383	0,434	0,375
Intervalo R-R (seg)	3,619	3,616	3,607	3,604	2,468	2,248	3,562	4,184	4,184	2,466	2,753	3,929	2,753	2,17

1.3.7 Flúter Auricular (AFL). Este es el registro electrocardiográfico tomado de la base de datos del *MIT-BIH Atrial Fibrillation/Flutter Database* (bmp)²¹.




Figura 21. Flúter Auricular (*Atrial flutter*)

Se observa en la figura 21, ocho ciclos cardiacos con una duración aproximadamente de 3,184 seg. El Flúter auricular aparece en todos los ocho ciclos de esta señal ventaneada, con una duración por ciclo de 0,398 seg, que equivale a un ritmo cardiaco de 150 latidos por minuto (bpm). En la siguiente tabla se puede apreciar otras características temporales de esta señal.

Tabla 32. Características temporales de Flúter Auricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
59	-0,053	0,425	3,184	146,971

En la tabla 33 se presentan los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal para la señal de la figura 21.

Tabla 33. Coeficientes de predicción lineal de Flúter Auricular

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-2,129	2,017	-0,935	-0,136

²¹ Registro 04908 del *MIT-BIH Atrial Fibrillation/Flutter Database*, www.physionet.org




Figura 22. Espectro en frecuencia del Flúter Auricular

En la figura 22 se puede apreciar parte del espectro del *Flutter* Auricular, donde existe un máximo en el espectro a una frecuencia de 5,026 Hz. Otras características frecuenciales de esta señal se observan en la siguiente tabla.

Tabla 34. Características del espectro frecuencial de Flúter Auricular

Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
5,026	17,904	24,980	27,179	0,744

Puede apreciarse que el ancho de banda donde esta el 95 % de la energía (calculadas a partir de la FFT) es de 17,904 Hz; la desviación estándar es de 24,98; la varianza es de 27,17 y el THD es de 0,74. Se presenta en la figura 23 otro Flúter Auricular (señal ventaneada) perteneciente a otro registro electrocardiográfico²²; que tiene una duración por ciclo de 0.625 seg, equivalente a 96 latidos por minuto (bpm). En la tabla 35 se pueden ver sus parámetros.

En la tabla 36 se presentan los respectivos parámetros temporales y frecuenciales de 14 diferentes señales de Flúter Auricular. Se puede apreciar que todas las señales tienden a tener una frecuencia máxima en su espectro cercana a 5,07 Hz (ya que su rango va de 5,02 hasta 5,17 Hz); otra particularidad es que su ancho de banda del 95% de la energía esta en valores

²² Registro: 8215 del *MIT-BIH Atrial Fibrillation/Flutter Database*

que oscilan entre 10,03 y 18,14 Hz; podría mencionarse que otro parámetro frecuencial como la desviación estándar está en un rango que oscila entre 17,41 y 27,87; la energía de la señal está en un rango que oscila entre 127,78 y 164,5 Hz .




Figura 23. Señal Flúter Auricular y su Espectro frecuencial

Tabla 35. Características temporales y frecuenciales de la señal Flúter Auricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
56	0,064	0,253	5,000	81,742
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-1,938	1,295	-0,607	0,142	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
4,800	19,200	6,387	6,058	1,124

Tabla 36. Patrones pertenecientes a otras 14 señales de Flúter Auricular

Parámetros	N1	N2	N3	N4	N5	N6	N7	N8	N9	N10	N11	N12	N13	N14
Cruces por cero	66	58	50	62	63	38	52	40	42	60	69	59	49	72
1-4 Coeficientes LPC	-1,995	-2,055	-2,065	-2,1	-2,04	-2,109	-2,058	-2,11	-2,125	-2,105	-2,058	-2,129	-2,098	-2,087
2-4 Coeficientes LPC	1,763	1,871	1,927	2,076	1,83	2,002	1,847	1,964	2,009	2,014	1,901	2,017	1,86	1,932
3-4 Coeficientes LPC	-0,768	-0,788	-0,982	-1,219	-0,768	-1	-0,709	-0,807	-0,987	-1,003	-0,842	-0,935	-0,618	-0,842
4-4 Coeficientes LPC	-0,056	-0,249	0,109	0,276	-0,164	0,007	-0,261	-0,277	0,003	0,001	-0,19	-0,136	-0,434	-0,158
Frecuencia Fundamental (Hz)	5,051	5,044	5,076	5,051	5,025	5,069	5,146	5,172	5,02	5,063	5,141	5,026	5,095	5,088
Ancho de Banda del 95% energía (Hz)	12,626	12,296	15,227	12,626	10,329	14,891	10,291	10,343	10,039	12,341	15,679	17,904	18,149	17,491
Desviación Estándar (Frec)	24,796	21,915	21,629	24,449	20,594	24,638	19,098	22,384	27,877	18,461	17,417	24,98	20,21	20,962
Varianza (Frec)	3,613	20,478	14,195	25,21	3,246	30,078	10,739	19,413	5,671	9,202	18,494	27,179	10,92	13,951
Energía (mV) ²	132,33	137,389	146,276	140,623	147,389	162,671	127,776	148,294	164,498	136,871	164,401	146,971	147,04	133,067
Media (mV)	0,024	-0,046	-0,101	-0,051	0,032	-0,133	-0,058	-0,128	-0,118	-0,028	-0,053	-0,053	0,177	0,062
THD	0,643	0,589	0,67	0,637	0,478	0,529	0,515	0,51	0,542	0,474	0,468	0,744	0,411	0,576
rms (mV)	0,404	0,411	0,426	0,416	0,401	0,449	0,401	0,433	0,449	0,411	0,406	0,425	0,428	0,407
Intervalo R-R (seg)	3,168	3,172	3,152	3,168	3,582	3,156	3,109	3,094	3,187	3,16	3,891	3,184	3,141	3,145

1.3.8 Taquiarritmia Supraventricular (*Supraventricular Tachyarrhythmia, SVTA*). Este es el registro electrocardiográfico tomado de la base de datos *MIT-BIH Supraventricular Arrhythmia Database* ²³.



Figura 24. Taquiarritmia Supraventricular

Se observa en la figura 24, ocho ciclos cardíacos con una duración de aproximadamente 3,271 seg. La Taquiarritmia Supraventricular aparece a partir del segundo ciclo de esta señal ventaneada, con una duración por ciclo de 0,408 seg, que equivale a un ritmo cardíaco de 146 latidos por minuto (bpm). En la tabla 37 se puede apreciar otras características temporales de esta señal.

Tabla 37. Características temporales de Taquiarritmia Supraventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
38	-0,088	0,542	3,271	119,190

En la tabla 38 se presentan los 4 primeros coeficientes del modelo AR orden 16 de predicción lineal para la señal de la figura 24.

Tabla 38. Coeficientes de predicción lineal de Taquiarritmia Supraventricular

1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A
-1,45	0,564	0,045	0,087

²³ Registro: 809 del *MIT-BIH Supraventricular Arrhythmia Database*, www.physionet.org




Figura 25. Espectro en frecuencia de la Taquiarritmia Supraventricular

En la figura 25 se puede apreciar parte del espectro de Taquiarritmia Supraventricular, donde existe un máximo en el espectro a una frecuencia de 7,638 Hz. Otras características frecuenciales de esta señal se observan en la siguiente tabla.

Tabla 39. Características del espectro frecuencial de Taquiarritmia Supraventricular

Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
4,891	9,783	7,036	4,017	0,714

Puede apreciarse que el ancho de banda donde esta el 95 % de la energía es de 9,783 Hz; la desviación estándar es de 7,03; la varianza es de 4,017 y el THD es de 0,714.

En la figura 26 se presenta otra señal ventaneada de la *Supraventricular tachyarrhythmia* perteneciente a otro registro electrocardiográfico²⁴ con una duración por ciclo de 0,432 equivalente a una frecuencia cardiaca de 138 latidos por minuto. En la tabla 40 se presentan los demás parámetros de la señal ventaneada.

En la tabla 41 se presentan los respectivos parámetros temporales y frecuenciales de 14 diferentes señales de Taquiarritmia Supraventricular. Se puede apreciar que todas las señales tienden a tener una frecuencia máxima

²⁴ Registro: 865 del MIT-BIH Atrial Fibrillation/Flutter Database

en su espectro cercana a 4,99 Hz (ya que su rango va de 4,9 hasta 5,14 Hz); otra particularidad es que su ancho de banda del 95% de la energía esta en valores que oscilan entre 12,35 y 15,04 Hz; podría mencionarse que otro parámetro frecuencial como la desviación estándar esta en un rango que oscila entre 3,47 y 31,24; la energía de la señal esta en un rango que oscila entre 34,54 y 113,26 Hz .

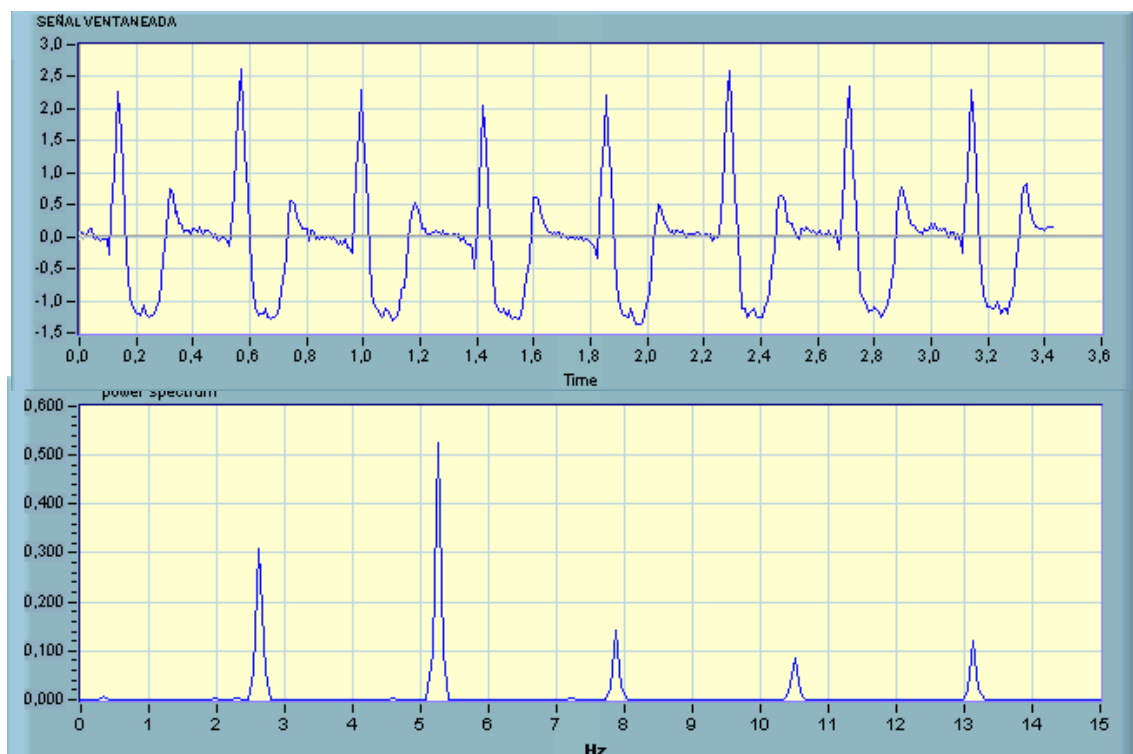


Figura 26. Señal Taquiarritmia Supraventricular y su Espectro frecuencial

Tabla 40. Características temporales y frecuenciales de la señal Taquiarritmia Supraventricular

Cruces por cero	Media (mV)	Valor rms (mV)	Intervalo R-R (seg)	Energía de la señal (mV) ²
32	0,176	0,802	3,463	278,798
1-4 coef. A	2-4 coef. A	3-4 coef. A	4-4 coef. A	
-1,321	0,288	0,120	0,214	
Frecuencia Fundamental (Hz)	Ancho de banda 95% E. (Hz)	Desviación Estándar	Varianza	THD
5,252	10,505	22,475	8,052	0,458

Tabla 41. Patrones pertenecientes a otras 14 señales de Taquiarritmia Supraventricular

Cruces por cero	36	34	24	23	40	32	32	22	28	20	29	15	24	26
1-4 Coeficientes LPC	-1,497	-1,321	-1,349	-1,353	-1,269	-1,393	-1,497	-1,541	-1,495	-1,301	-1,496	-1,367	-1,29	-1,249
2-4 Coeficientes LPC	0,643	0,489	0,606	0,575	0,391	0,606	0,631	0,782	0,641	0,502	0,657	0,577	0,427	0,391
3-4 Coeficientes LPC	0,011	0,185	0,04	0,192	0,286	0,197	0,006	-0,068	-0,006	0,239	-0,022	0,083	0,264	0,251
4-4 Coeficientes LPC	0,093	0,141	0,23	0,034	0,179	-0,042	0,122	-0,032	0,104	0,109	0,096	0,101	0,165	0,217
Frecuencia Fundamental (Hz)	4,93	4,93	4,948	4,9	4,952	4,916	4,951	5,001	5,008	5,041	5,081	5,016	5,102	5,144
Ancho de Banda del 95% energía (Hz)	12,76	12,403	12,474	12,351	12,459	12,366	12,377	15,004	12,52	12,729	12,702	15,048	12,884	12,86
Desviación Estándar (Frec)	3,981	4,684	4,492	3,473	4,915	31,246	7,286	8,312	7,751	4,876	6,121	4,882	5,872	5,69
Varianza (Frec)	28,896	11,494	17,84	7,055	12,373	14,632	18,136	5,288	10,615	9,773	4,898	30,718	16,177	18,585
Energía (mV) ²	113,26	71,438	47,965	42,516	71,49	58,111	100,941	65,369	86,411	36,673	99,8	34,541	41,54	45,082
Media (mV)	-0,193	-0,07	-0,14	-0,14	-0,09	-0,17	-0,073	-0,073	-0,063	-0,13	-0,093	-0,24	-0,1	-0,11
THD	0,658	0,861	0,94	0,863	0,802	0,949	0,825	1,007	0,862	0,95	0,366	0,83	0,938	0,415
rms (mV)	0,514	0,418	0,399	0,374	0,422	0,379	0,536	0,509	0,535	0,383	0,54	0,415	0,41	0,429
Intervalo R-R (seg)	3,448	3,245	2,425	2,449	3,231	3,255	2,825	2	2,396	1,984	2,757	1,595	1,96	1,944

1.4 Conclusión

Con base a las tablas 6, 11, 16, 21, 26, 31, 36, 41 y en las figuras anteriores se observa que un parámetro a tener en cuenta es la frecuencia cardiaca (latidos/minutos) de la señal, que refleja cambios notorios en el espectro de frecuencia. Las figuras ilustran que el corrimiento de las componentes espectrales es relativamente notorio, teniendo en cuenta que sus frecuencias fundamentales son muy cercanas. Esto se ve claramente con la frecuencia fundamental del Bigeminismo Ventricular (B) que tiene un rango que está comprendido entre los 2,104 Hz y 2,194 Hz; y que esta muy cerca del rango de la frecuencia fundamental del Trigeminismo Ventricular (T) que va de los 2,322 Hz y 2,559 Hz. Lo mismo se puede decir de la Bradicardia Sinusal (SBR) la cual presenta un rango en la frecuencia fundamental de 2,465 Hz a 2,711 Hz. La única forma de discriminar estas señales sería con otro parámetro, para este caso sería la energía de la señal (Teorema de Parseval), que para la Bradicardia Sinusal está en el rango de 33,62 hasta 62,37; para el Bigeminismo Ventricular (B) en el rango de 104,63 hasta 149,26 ; para el Bigeminismo Ventricular (T) en el rango de 215,01 hasta 731,49 .

Otro caso donde existe mucha similitud en la frecuencia fundamental es la Fibrilación Auricular (AFIB) que esta en un rango de 3,99 Hz hasta 4,561 Hz ; muy cercano al rango comprendido entre 4,9 Hz hasta 5,144 Hz para la frecuencia fundamental de la Taquicardia Ventricular (SVTA). De nuevo la única forma de hacer una distinción entre estas señales es con la utilización de otros parámetros como: los cruces por cero de la señal y el valor rms (mV) parámetros temporales que hacen una marcada diferencia en la forma de onda en el tiempo. Es así que para la Taquicardia Supraventricular los cruces por cero están en un rango que va de los 15 a 40, y el valor rms esta en el rango de 0,374 mV hasta 0,54 mV; para la Fibrilación Auricular los cruces por cero están en un rango que va de los 44 a 250, y el valor rms esta en el rango de 0,104 mV hasta 0,311 mV. Por último se presenta otros resultados similares como son el rango de frecuencias fundamentales de las siguientes señales: Taquicardia Ventricular (SVTA) que va de 4,9 Hz hasta 5,144 Hz ; Flúter

Auricular (AFL) que va de 5,02 Hz hasta 5,172 Hz ; Taquicardia Ventricular (VT) que va de 5.25 Hz hasta 5,614 Hz. Puede verse una clara distinción entre estas señales al observar otros parámetros como la energía de la señal (teorema de Parseval) donde para la Taquicardia Supraventricular esta en el rango de 34,54 hasta 113,26 ; y el Flúter Auricular está en el rango de 127,78 hasta 164,5. Otro parámetro es Desviación Estándar (dominio Frecuencia) que para el Flúter Auricular está en el rango de 17,41 hasta 27,87 Hz; y la Taquicardia Ventricular está en el rango de 7,23 hasta 20,15 Hz, puede incluirse los Coeficientes de Predicción Lineal que para el Flúter Auricular está en el rango de: -2,129 hasta -1,995 para el primer coeficiente; 1,763 hasta 2,076 para el segundo coeficiente; -1,219 hasta -0,618 para el tercer coeficiente; -0,434 hasta 0,276 para el cuarto coeficiente; para la Taquicardia Ventricular está en el rango de: -2,305 hasta -1,914 para el primer coeficiente; 0,87 hasta 1,827 para el segundo coeficiente; -0,492 hasta 0,328 para el tercer coeficiente; -0,318 hasta -0,078 para el cuarto coeficiente. Aquí hay una diferencia en el rango de valores para el tercer coeficiente como puede verse que ayuda hacer una distinción entre Flúter Auricular y la Taquicardia Ventricular.

Finalmente la distinción entre Taquicardia Supraventricular y Taquicardia Ventricular se puede hacer al observar los coeficientes de predicción lineal, pues para la Taquicardia Supraventricular está en el rango de: -1,541 hasta -1,249 para el primer coeficiente; 0,391 hasta 0,782 para el segundo coeficiente; -0,068 hasta 0,286 para el tercer coeficiente; -0,042 hasta 0,23 para el cuarto coeficiente; para la Taquicardia Ventricular está en el rango de: -2,305 hasta -1,914 para el primer coeficiente; 0,87 hasta 1,827 para el segundo coeficiente; -0,492 hasta 0,328 para el tercer coeficiente; -0,318 hasta -0,078 para el cuarto coeficiente. Como puede verse hay una diferencia para el rango de valores para el primer, segundo y cuarto coeficiente de predicción lineal que ayuda hacer una clara distinción entre Taquicardia Supraventricular y Taquicardia Ventricular. En la tabla 42 puede observarse el rango de valores de los 14 parámetros temporales y frecuenciales de las siete arritmias estudiadas en este proyecto a las tablas 6, 11, 16, 21, 26, 31, 36, 41.

Tabla 42. Rango de valores de los parámetros temporales y frecuenciales de las siete arritmias cardiacas y el ritmo cardiaco normal

Parámetro	N		SBR		AFIB		AFL		SVTA		B		T		VT	
Cruces por cero	93	188	92	162	44	250	38	72	15	40	26	67	10	126	24	56
1-4 Coeficientes LPC	-2,147	-0,777	-1,845	-1,48	-1,991	-1,433	-2,129	-1,995	-1,541	-1,249	-2,232	-1,688	-2,11	-1,785	-2,305	-1,914
2-4 Coeficientes LPC	0,285	1,817	0,042	0,629	0,262	1,454	1,763	2,076	0,391	0,782	0,387	1,385	0,607	1,136	0,87	1,827
3-4 Coeficientes LPC	-1,14	0,46	0,28	0,62	-0,52	0,464	-1,219	-0,618	-0,068	0,286	0,25	0,558	0,121	0,402	-0,492	0,328
4-4 Coeficientes LPC	-0,479	0,333	-0,017	0,264	-0,494	0,104	-0,434	0,276	-0,042	0,23	-0,559	0,104	-0,437	-0,082	-0,318	-0,078
Frecuencia Fundamental (Hz)	1,021	1,596	2,465	2,711	3,99	4,561	5,02	5,172	4,9	5,144	2,104	2,194	2,322	2,559	5,25	5,614
Ancho de Banda del 95% energía (Hz)	5,54	25,99	8,05	10,10	11,05	31,48	10,03	18,14	12,35	15,04	10,13	12,65	2,16	14,53	10,59	14,50
Desviación Estándar (Frec)	8,189	22,972	4,318	15,36	3,313	21,711	17,417	27,877	3,473	31,246	9,37	14,672	3,235	26,198	7,23	20,151
Varianza (Frec)	3,429	24,001	3,236	31,284	3,506	25,76	3,246	30,078	4,898	30,718	3,285	30,58	3,749	26,59	3,853	24,024
Energía (mV) ²	25,673	427,59	33,62	62,377	5,711	118,31	127,78	164,5	34,541	113,26	104,63	149,26	215,01	731,49	92,385	191,7
Media (mV)	-0,13	0,034	-0,028	0,03	-0,13	0,028	-0,133	0,177	-0,24	-0,063	-0,086	0,021	-0,306	0,03	-0,1	0,022
THD	0,503	1,759	0,32	0,879	0,331	1,434	0,411	0,744	0,366	1,007	0,56	1,171	0,28	0,822	0,27	0,678
rms (mV)	0,132	0,582	0,113	0,169	0,104	0,311	0,401	0,449	0,374	0,54	0,327	0,359	0,379	0,567	0,326	0,434
Intervalo R-R (seg)	4,266	7,076	4,815	8,103	1,722	8,671	3,094	3,891	1,595	3,448	3,214	5,141	3,439	7,121	2,17	4,184

2. APLICACIÓN CON REDES NEURONALES ARTIFICIALES EN EL RECONOCIMIENTO DE ARRITMIAS²⁵

2.1 Modelo de neurona artificial

Las redes neuronales artificiales pretenden emular la red neuronal biológica y se obtienen interconectando neuronas. Para ello se supone un modelo matemático simplificado de la neurona biológica.

Este modelo es una generalización del propuesto por McCulloch y Pitts en 1943:

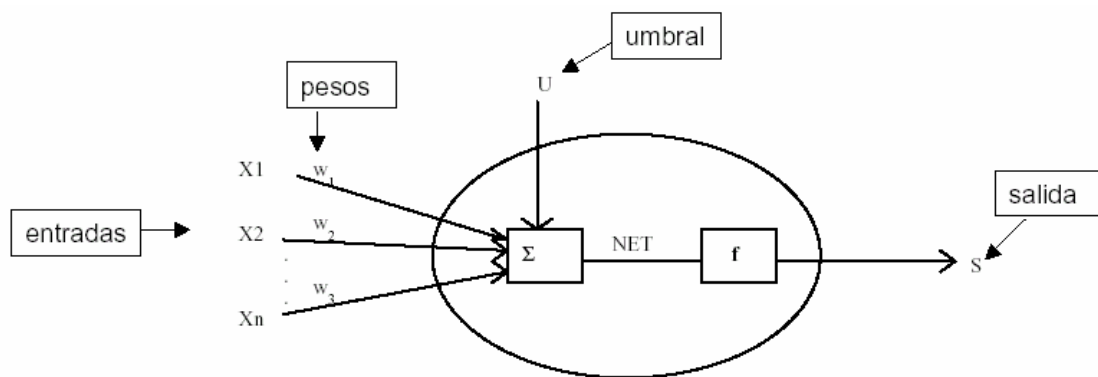


Figura 27. Modelo de neurona artificial

La salida de la neurona es:

$$Y = f(NE T) \quad (1)$$

f es la función de activación

$$NE T = X_1 \times w_1 + X_2 \times w_2 + \dots + X_n \times w_n + U = \sum_{i=1}^n X_i \times w_i + U \quad (2)$$

²⁵ Arritmias provenientes de la base de datos del MIT (*Massachusetts Institute of Technology*), www.physionte.org, ver capítulo 1.

La neurona recibe del exterior un umbral U y N entradas a las que asocia un conjunto de pesos w_i ($i = 1, \dots, N$). Aplicando el producto de los pesos por las entradas respectivas más el umbral (o desplazamiento) a una función de activación $f(\text{net})$, se obtiene la salida "Y" ecuación (1).

Como se muestra en la figura 27, la neurona se activa si la fuerza combinada de la señal de entrada es superior a un cierto nivel, en el caso general el valor de activación de la neurona viene dado por una función de activación $f(\text{net})$.

2.1.1 Elementos básicos que componen una red neuronal

A continuación se puede ver, en la *Figura 28.*, un esquema de una red neuronal:




Figura 28. Ejemplo de una red neuronal totalmente conectada.

La misma está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la "capa de entrada", pasan a través de la "capa oculta" y salen por la "capa de salida". Cabe mencionar que la capa oculta puede estar constituida por varias capas.²⁶

²⁶ * MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones.
<http://www.modeloingenieria.edu.ar/utnffro/orientacion/monografias/matich-redesneuronales.pdf>

2.1.2 Funciones de Activación (*activation function*)

La *función activación* o *transferencia* $f(\text{NET})$ calcula el estado de actividad de una neurona; transformando la entrada global (menos el umbral, U) en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1). Las funciones de activación más comúnmente utilizadas se detallan a continuación:

1) *Función lineal (PURELIN):*




Figura 29. Función de activación lineal.

Por encima o por debajo de esta zona se fija la salida en 1 o -1, respectivamente. Cuando $x = 1$ (siendo que la misma afecta la pendiente de la gráfica), la salida es igual a la entrada.²⁷

2) *Función sigmoidea (LOGSIG):*





Figura 30. Función de activación Sigmoidea

Los valores de salida que proporciona esta función están comprendidos dentro de un rango que va de 0 a 1.

²⁷ NEURAL NETWORK TOOLBOX, for use with MATLAB,

3) Función tangente hiperbólica (TANSIG):




$$f(\text{net}) = \frac{2}{1 + e^{-2n}} - 1 \quad (5)$$

Figura 31. Función de activación tangente Hiperbólica

Los valores de salida de la función tangente hiperbólica están comprendidos dentro de un rango que va de -1 a 1. Al modificar el valor de g se ve afectada la pendiente de la función de activación.


4) Función gaussiana (RADBAS):



$$f(\text{net}) = e^{-n^2} \quad (6)$$

Figura 32. Función de activación *gaussiana*.

5) Función Escalón (HARDLIM):



$$f(\text{net}) = \begin{cases} 0 & n < 0 \\ 1 & n \geq 0 \end{cases} \quad (7)$$

Figura 33. Función de activación escalón.

Tabla 43. Patrones temporales y frecuenciales pertenecientes a las siete clases de arritmias y el ritmo cardiaco normal.

	1	2	3	...	516	517	518	...	712	713	...
Cruces * cero	10	11	11	...	11	11	11	...	13	12	...
1-4 coef. A	-2,31	-2,33	-2,33	...	-2,30	-2,31	-2,30	...	-2,29	-2,28	...
2-4 coef. A	2,90	2,97	2,99	...	2,86	2,89	2,86	...	2,87	2,83	...
3-4 coef. A	-2,73	-2,87	-2,89	...	-2,63	-2,72	-2,63	...	-2,69	-2,59	...
4-4 coef. A	2,19	2,40	2,43	...	2,03	2,17	2,03	...	2,16	2,01	...
Frec. Reson.	1,68	4,65	5,57	...	0,80	0,80	0,84	...	5,17	6,25	...
Ancho Banda	16,81	15,48	13,91	...	8,00	8,00	8,41	...	22,17	20,84	...
D.E (frec)	0,20	0,30	0,25	...	0,12	0,12	0,13	...	0,55	0,61	...
Varianza (frec)	0,04	0,09	0,06	...	0,02	0,02	0,02	...	0,30	0,38	...
Energía D.T	6,56	6,65	6,66	...	6,53	6,62	6,53	...	6,56	6,46	...
Mediam D.T	-42,5	-41,3	-15,0	...	20,0	20,0	20,0	...	-37,5	-60,0	...
Varianza D.T	48,4	46,8	43,1	...	26,4	26,7	26,6	...	47,0	56,9	...
rms	234,8	231,6	219,6	...	164,9	166,0	165,6	...	231,0	259,5	...
Per. QRS (ms)	1190	1292	1438	...	2500	2500	2380	...	1353	960	...
Tipo de patron	1	1	1	...	2	2	2	...	3	3	...

	861	...	900	901	...	1300	1301	...	1324	1325	1326
Cruces * cero	7	...	12	11	...	17	14	...	8	7	10
1-4 coef. A	-2,22	...	-2,25	-2,23	...	-1,52	-1,28	...	-2,13	-2,13	-2,03
2-4 coef. A	2,59	...	2,70	2,65	...	1,03	0,76	...	2,32	2,32	2,16
3-4 coef. A	-2,11	...	-2,36	-2,28	...	-0,18	0,12	...	-1,26	-1,21	-1,50
4-4 coef. A	1,30	...	1,66	1,57	...	-0,23	-0,35	...	-0,03	-0,18	0,72
Frec. Reson.	5,38	...	4,47	4,92	...	0,00	6,14	...	7,62	3,23	5,93
Ancho Banda	26,87	...	14,90	16,39	...	6,25	17,54	...	57,14	64,52	16,95
D.E (frec)	1,86	...	0,45	0,47	...	0,13	0,43	...	0,37	0,55	0,43
Varianza (frec)	3,46	...	0,20	0,23	...	0,02	0,19	...	0,14	0,30	0,18
Energía D.T	6,22	...	6,63	6,63	...	6,60	5,80	...	4,89	4,96	5,80
Mediam D.T	-42,5	...	13,8	15,0	...	-66,3	-61,3	...	32,5	42,5	18,8
Varianza D.T	90,3	...	51,6	51,6	...	34,1	43,4	...	46,6	53,7	47,0
rms	327,4	...	233,2	233,2	...	203,1	225,5	...	215,8	231,0	221,6
Per. QRS (ms)	744	...	1342	1220	...	1600	1140	...	1050	930	1180
Tipo de patron	4	...	4	4	...	4	4	...	5	5	5

	1599	1600	1601	..	2027	2028	..	2153	2154	..	2271
Cruces * cero	12	12	11	...	11	11	...	14	14	...	4
1-4 coef, A	-2,15	-2,15	-2,19	...	-2,35	-2,35	...	-2,32	-2,32	...	-1,46
2-4 coef, A	2,48	2,48	2,55	...	2,99	2,99	...	2,92	2,92	...	0,44
3-4 coef, A	-2,13	-2,13	-2,20	...	-2,86	-2,86	...	-2,73	-2,73	...	0,30
4-4 coef, A	1,54	1,54	1,58	...	2,32	2,32	...	2,17	2,17	...	-0,10
Frec, Reson,	3,44	3,20	3,31	...	4,71	4,71	...	0,76	0,76	...	2,44
Ancho Banda	11,48	10,66	16,53	...	9,41	9,41	...	7,56	7,56	...	0,81
D,E (frec)	0,34	0,34	0,44	...	0,15	0,15	...	0,08	0,08	...	1,03
Varianza (frec)	0,12	0,12	0,19	...	0,02	0,02	...	0,01	0,01	...	1,06
Energía D,T	6,46	6,46	6,55	...	6,51	6,51	...	6,58	6,58	...	8,13
Mediam D,T	20,0	20,0	-15,0	...	20,0	20,0	...	20,0	20,0	...	0
Varianza D,T	45,8	45,8	49,1	...	30,6	30,6	...	25,1	25,1	...	47,5
rms	219,5	219,5	232,7	...	178,7	178,7	...	161,0	161,0	...	222,7
Per. QRS (ms)	1742	1876	1210	...	2125	2125	...	2646	2646	...	1640
Tipo de patrón	6	6	6	...	7	7	...	8	8	...	8

2.2 Preparación y codificación de los datos

Los datos que se suministraran a la red neuronal son todos los patrones o características extraídos de las siete arritmias estudiadas anteriormente mas los patrones característicos del ritmo cardiaco normal (columnas interiores de la tabla 43) que hacen un total de 2271 patrones correspondientes a ocho clases de patrones a reconocer (última fila de la tabla 43).

Todos estos elementos se organizaron en una matriz de entrada para ser presentados a la red neuronal.

Para ilustrar la forma en que se organizaron los datos:

$$P = \begin{bmatrix} 11 & \dots & 11 & \dots & 13 & \dots & 7 & \dots & 11 & \dots & 4 & \dots & 15 & \dots & 10 & \dots & 9 \\ -2.33 & \dots & -2.31 & \dots & -2.29 & \dots & -2.22 & \dots & -2.23 & \dots & -1.80 & \dots & -2.23 & \dots & -1.66 & \dots & -1.66 \\ 2.98 & \dots & 2.89 & \dots & 2.88 & \dots & 2.59 & \dots & 2.66 & \dots & 0.96 & \dots & 2.44 & \dots & 1.02 & \dots & 1.04 \\ -2.89 & \dots & -2.72 & \dots & -2.71 & \dots & -2.11 & \dots & -2.29 & \dots & -0.32 & \dots & -1.82 & \dots & -0.19 & \dots & -0.23 \\ 2.43 & \dots & 2.17 & \dots & 2.19 & \dots & 1.30 & \dots & 1.58 & \dots & 0.39 & \dots & 0.93 & \dots & -0.08 & \dots & -0.05 \\ 5.79 & \dots & 0.80 & \dots & 6.08 & \dots & 5.38 & \dots & 4.92 & \dots & 1.47 & \dots & 4.58 & \dots & 4.33 & \dots & 5.82 \\ 1.44 & \dots & 0.89 & \dots & 1.73 & \dots & 2.99 & \dots & 1.64 & \dots & 0.74 & \dots & 0.83 & \dots & 0.87 & \dots & 1.16 \\ 0.92 & \dots & 0.00 & \dots & 1.38 & \dots & 0.01 & \dots & 1.54 & \dots & 1.49 & \dots & 0.68 & \dots & 0.44 & \dots & 0.76 \\ 0.85 & \dots & 0.00 & \dots & 1.91 & \dots & 0.00 & \dots & 2.36 & \dots & 2.23 & \dots & 0.46 & \dots & 0.20 & \dots & 0.58 \\ 6.65 & \dots & 6.62 & \dots & 6.55 & \dots & 6.22 & \dots & 6.63 & \dots & 19.94 & \dots & 12.29 & \dots & 7.42 & \dots & 7.37 \\ -15 & \dots & 20 & \dots & -45 & \dots & -42.5 & \dots & -15 & \dots & 35 & \dots & 12.5 & \dots & 3.8 & \dots & 0.0 \\ 43.06 & \dots & 26.7 & \dots & 49.51 & \dots & 90.3 & \dots & 51.6 & \dots & 75.2 & \dots & 49.7 & \dots & 32.1 & \dots & 41.6 \\ 219.63 & \dots & 166 & \dots & 238.82 & \dots & 327.4 & \dots & 233.2 & \dots & 276.4 & \dots & 226.3 & \dots & 182.8 & \dots & 211.3 \\ 1,380 & \dots & 2,5 & \dots & 1,15 & \dots & 0,744 & \dots & 1,220 & \dots & 2,719 & \dots & 2,4 & \dots & 2,312 & \dots & 1,719 \end{bmatrix}$$

14×2271

(8)

donde:

P: son los valores de entrada a la red, que se agruparon en el matriz de [14 x 2271], los cuales corresponden a los patrones de tiempo y frecuencia, anteriormente mencionados (columnas de la tabla 43).

Las salidas deseadas (última fila referente al tipo de patrón en la tabla 43), se organizaron en un vector de [1x2271] para ser suministrado a la red neuronal.

$$T = [1... 2... 3... 4... 5... 6... 7... 8]_{1 \times 2271} \quad (9)$$

donde:

T: vector correspondiente a las salidas deseadas de la red, que equivalen al “tipo de patrón”, enumerado de 1 al 8, que es en sí la forma cómo se codificó las siete clases de arritmias mas el ritmo cardiaco normal, asignando un número como se puede ver en la siguiente tabla.

Tabla 44. Codificación de acuerdo a las clases de arritmias

Tipo de patrón	Clase de arritmia
1	Ritmo Cardiaco Normal
2	Bradicardia Sinusal
3	Taquicardia Ventricular
4	Taquicardia Supraventricular
5	Flúter Auricular
6	Fibrilación Auricular
7	Bigeminismo Ventricular
8	Trigeminismo Ventricular

2.2.1 Preprocesamiento de los datos de Entrenamiento

Seleccionados los datos de entrada, se tiene que hacer un preprocesamiento antes de suministrarlos a la red neuronal. Estos valores fueron normalizados, ya que de esta forma se obtiene una mejor generalización de la red en el proceso de aprendizaje. El proceso de normalización consiste en dividir cada uno de los valores interiores de la matriz P (ecuación 8) por el valor máximo de todas las columnas interiores de esta misma matriz, de tal forma que el mayor valor de entrada a la red será uno.

$$\text{Valor normalizado} = \frac{\text{Valor}}{\text{Valor}_{\text{máximo}}} \quad (10)$$

La normalización se realizó en un rango de oscilación de los datos entre -0.0213 y 1, un rango apropiado para la función de activación *sigmoide tangencial*²⁸ (*TANSIG*), puesto que sus valores de salida están en el rango en entre -1 y 1; los mejores resultados se obtuvieron utilizando como funciones de activación *sigmoide tangencial* (*TANSIG*) y la lineal (*PURELIN*) en la capa oculta y de salida respectivamente.

2.3 Topología de la Red Backpropagation

2.3.1 Justificación del tipo de Red Backpropagation

Se encontró que en la mayoría de textos e investigaciones²⁹ acerca de redes neuronales artificiales con aplicaciones en cardiología se ha utilizado la red

²⁸ Funciones de Activación capítulo 1. (sección 1.3.2)

²⁹ ***HILERA González**, José Ramón “Redes Neuronales Artificiales Fundamentos, Modelos y Aplicaciones”. Departamento de Arquitectura y Tecnología de Computadores. Universidad Politécnica de Madrid. ADDISON-WELEY IBEROAMERICANA. Pag 155-164

* **BORTOLAN** Giovanni ,**DEGANI** Rosanna.“Neural Networks for ECG Classification” University of Leuren , Belgium, IEEE 1991

* **SIED Khursheed Ul Hasnain**. “Artificial Neural Networks in Cardiology – ECG wave Analysis and Diagnosis Using Backpropagation Neural Networks”. IEEE 1999

backpropagation con excelentes resultados debido a su buena capacidad de reconocer patrones. Por esta razón en este proyecto se decidió implementarla.

El algoritmo *Backpropagation*³⁰ es un método de aprendizaje supervisado, el cual necesita conocer la salida esperada (columna referente al tipo de patrón en la tabla 43) asociada a cada una de las entradas (columnas interiores de la tabla 43), que actualiza pesos y ganancias siguiendo la regla de pasos descendientes, siguiendo la regla de aprendizaje de retropropagación (*Backpropagation*) en la cual se busca minimizar el error cuadrático en las salidas de la red.

2.3.2 Especificación de la Arquitectura de la Red *Backpropagation*

Una vez definido el algoritmo de entrenamiento, la función de activación y regla de aprendizaje, es necesario establecer el número de neuronas por capa con el fin de obtener a la salida de la red el menor error posible en la tarea de identificar los diferentes patrones pertenecientes a las arritmias a reconocer.

No hay ningún criterio establecido para predecir la arquitectura final de la red, la elección del número de capas que la componen y el número de neuronas de cada una de ellas es fijado por la experiencia del diseñador y muchas veces es realizado por un método de ensayo y error.

Por esta razón se procedió primero que todo a definir tres capas: una capa de entrada, una capa oculta o intermedia y una de salida con funciones de activación *sigmoide tangencial* (**TANSIG**); *sigmoide tangencial* (**TANSIG**) y *lineal* (**PURELIN**), respectivamente.

2.3.3 Entrenamiento de la Red *Backpropagation*

Al seleccionar el algoritmo *Backpropagation*, que es un método de aprendizaje supervisado, el entrenamiento de la red tiene por lo tanto que ser supervisado, en el cual a la red se le suministran no solo los valores de entrada (matriz P) sino también los valores de salida deseados o objetivo (vector T).

³⁰ En el Anexo K. se especifica la redes neuronales más conocidas

El código de entrenamiento para esta red fue desarrollado con base en la herramienta de redes neuronales de Matlab 5.3³¹. La ejecución de los comandos se realiza teniendo en cuenta el siguiente orden:

1. Normalizar las entradas (matriz P) con el comando ***premnmx***.

```
[pn]=premnmx(P); %normalizar las entradas
```

2. Crear la red *Backpropagation* mediante el comando ***newff*** con las siguientes características:

```
net=newff(minmax(pn),[14,16,1],
          {'tansig','tansig','purelin'},'trainlm');
```

Aquí al comando ***newff*** se le tiene que especificar primero el rango (valores máximo y mínimo) de cada una de las filas de la matriz “*pn*” (matriz P normalizada), esto se realiza con el comando ***minmax***. Segundo, el número de neuronas de cada capa; inicialmente se decidió en este proyecto trabajar con 14 neuronas en la capa de entrada, 16 neuronas en la capa oculta, y una neurona en la capa de salida. Tercero, las funciones de transferencia en cada una de las capas; aquí ***tansig***, ***tansig***, ***purelin*** en su orden respectivo. Por último se tiene que especificar el algoritmo de entrenamiento a utilizar; para este caso ***trainlm***, este algoritmo actualiza los pesos y las ganancias de acuerdo a la optimización de *Levenberg- Marquardt*³².

3. Se tiene que especificar el número máximo de iteraciones así como también el error mínimo que tiene que alcanzar la red en su etapa entrenamiento. Después de varias pruebas, los parámetros que determinan el entrenamiento se fijaron en

³¹ En el anexo E se describen las funciones utilizadas en Matlab

³² Ver el anexo K, donde se explica la base matemática del algoritmo de Levenberg-Marquardt

los siguientes valores, mediante los cuales se alcanzó el rendimiento óptimo de la red.

```
net.trainParam.show = 10;      %Intervalo de visualización
                                %de los resultados
net.trainParam.epochs = 5000; %máximo número de iteraciones
                                %del entrenamiento
net.trainParam.goal = 1e-5;    %Error deseado
```

Aquí se puede apreciar como con el comando ***net.trainParam.show*** se le asigna un valor de 10 equivalente a mostrar resultados del error de la red cada 10 iteraciones; el comando ***net.trainParam.epochs*** se le asigna un valor de 5000 equivalente al número máximo de iteraciones en la etapa de entrenamiento de la red; el comando ***net.trainParam.goal*** es el mínimo error que tiene la red que alcanzar para detener el entrenamiento.

4. Entrenar la red con el comando ***train***

```
red = train(net,pn,T);          %Entrenamiento de red
```

El comando ***train*** se le tiene que especificar cual es la red a entrenar (*net*), la entradas a la red (*pn*) y la salida deseada (*T*).

5. Probar la red con el comando ***sim***

```
y = sim(red,pn);               %Prueba de la red
```

2.4 Implementación del modelo de *Red Base Radial*

Para poder comparar el desempeño de la red Backpropagation, se decidió en este proyecto implementar otra red que posea similares características y propiedades en cuanto a tareas de clasificación de patrones.

Por lo tanto se optó por el algoritmo de Base Radial (*RBF*)³³ que es un método de aprendizaje supervisado, el cual necesita conocer la salida esperada (última fila “tipo de patrón” de la tabla 43), asociada a cada una de las entradas (columnas interiores de la tabla 43). Una de las mayores ventajas de las redes de Base Radial, es que pueden cubrir espacios de altas dimensiones, como se presentan en este problema, además de que aprenden de manera muy eficiente³⁴ (mayor rapidez de entrenamiento), una vez que se han determinado los centros, ya que el error es lineal respecto a los pesos.

Ya que este algoritmo es completamente cerrado³⁵, no se puede manipular el número de capas y el número de neuronas en cada una de ellas. De esta manera solo se presentan los datos de entrada y las salidas deseadas y el algoritmo trabaja internamente con dos capas (La primera capa tiene neuronas **RADBAS**. La segunda capa de salida tiene neuronas **PURELIN**), acomodando los pesos y el número de neuronas de acuerdo a las entradas y salidas presentadas a la red.

2.4.1 Entrenamiento de la Red Base Radial

Al igual que antes, el entrenamiento de la red se hizo con todos los valores de entrada que conforman el *set* de entrenamiento (valores de entrada tabla 43). La ejecución de los comandos en Matlab para el entrenamiento de la red se realiza en el siguiente orden:

1. Crear y entrenar la red *Base Radial* mediante el comando **newrb**

³³ En el Anexo K. se especifica la redes neuronales más conocidas

³⁴ Aunque esto implique un número mayor de neuronas en la capa oculta.

³⁵ Para los usuarios del Toolbox de Matlab 5.3

```
red = newrb(P,T);           % diseño una red de base radial.
```

Al comando **newrb** se le tiene que especificar cual es la entrada a la red (P) y la salida deseada (T).

2. Probar la red con el comando **sim**

```
a = sim(red,P);           %Prueba de la red
```

2.5 Pruebas del desempeño de la Red (**Backpropagation y Base Radial**)

Para el entrenamiento de la red neuronal se ha utilizado la Serie 100 de la base de datos del MIT/ BIH (*Arrhythmia Database*) por presentar una amplia variedad de formas de onda. De cada fichero se ha seleccionado 5 minutos de la señal donde aparece una anomalía (arritmia), tiempo que consideramos suficiente para la fase de entrenamiento ya que en algunos registros el número de pulsos (*beats*) anormales solo llega a unos cuantos minutos como se puede observar en el registro 213 donde la arritmia tiene una duración de 1.04 minutos; y en otros casos llega tan solo a unos cuantos segundos como se puede ver en el registro 220 donde la arritmia tiene duración tan solo de 16 seg., como se puede apreciar en la tabla 45 donde se puede examinar la totalidad de los registros

Para poder validar el trabajo de la red neuronal y así saber cuanta exactitud posee en la tarea de reconocimiento de arritmias, se prueba el sistema con la totalidad de los pulsos de cada fichero garantizando que la red vea pulsos nunca antes vistos para analizar su desempeño en la clasificación y reconocimiento de los diferentes latidos.

En la tabla 46 se presentan los resultados de reconocimiento de los latidos por parte la red neuronal, se observa que se produce 20673 latidos falsos positivos (FP: Latidos detectados como enfermos cuando verdaderamente están sanos) equivalente al 36.61% y 3525 latidos falsos negativos (FN: Latidos detectados

como sanos pero realmente están enfermos) equivalente al 6.24%, para un total 24198 latidos identificados como erróneos. De lo anterior se puede concluir que se reconoce latidos sanos de los enfermos con una eficiencia del 57.14 %.

Tabla 45. Registros de la base de datos de arritmias (*Arrhythmia Database*)³⁶

Record	N	SBR	SVTA	AFL	AFIB	B	T	VT
100	30:06	-	-	-	-	-	-	-
101	30:06	-	-	-	-	-	-	-
103	30:06	-	-	-	-	-	-	-
104	30:06	-	-	-	-	-	-	-
105	30:06	-	-	-	-	-	-	-
106	22:36	-	-	-	-	7:10	0:13	0:02
119	22:36	-	-	-	-	3:55	3:34	-
122	30:06	-	-	-	-	-	-	-
123	30:06	-	-	-	-	-	-	-
124	28:36	-	-	-	-	-	0:22	-
210	-	-	-	-	29:30	0:23	0:07	0:06
212	30:06	-	-	-	-	-	-	-
213	29:01	-	-	-	-	1:00	-	0:04
214	28:53	-	-	-	-	-	1:08	0:05
215	30:03	-	-	-	-	-	-	0:01
217	25:10	-	-	-	4:06	0:32	-	0:02
220	29:50	-	0:16	-	-	-	-	-
221	-	-	-	-	29:17	0:03	0:37	0:04
222	15:57	-	0:08	0:15	8:33	-	-	-
223	23:23	-	-	-	-	4:19	0:21	1:46
228	24:17	-	-	-	-	5:48	-	-
232	-	30:06	-	-	-	-	-	-
233	28:03	-	-	-	-	1:48	0:04	0:11
234	29:40	-	0:26	-	-	-	-	-

³⁶ El registro 222 tiene algunas ondas QRS inusualmente grandes morfológicamente.

Tabla 46. Resultados de la detección del sistema utilizado

Record	Total latidos	FP (latidos)	FN (latidos)	No. de latidos detectados erróneos	Porcentaje Latidos detectados erróneos (%)
100	2273	326	0	326	14,34
101	1865	262	0	262	14,05
103	2084	468	0	468	21,40
104	2229	347	1	348	15,61
105	2572	362	3	365	14,19
106	2027	588	239	827	40,80
119	1987	625	249	874	43,99
122	2476	1051	0	1051	42,45
123	1518	956	0	956	62,98
124	1619	1058	3	1061	65,53
210	2650	897	83	980	36,98
212	2748	1410	0	1410	51,31
213	3251	1261	264	1525	46,91
214	2262	1015	165	1180	52,17
215	3363	1206	0	1206	35,86
217	2208	1053	52	1105	50,05
220	2048	1057	0	1057	51,61
221	2427	0	1481	1481	61,02
222	2484	1476	70	1546	62,24
223	2605	1327	268	1595	61,23
228	2053	846	145	991	48,27
232	1780	784	0	784	44,04
233	3079	902	502	1404	45,60
234	2753	1396	0	1396	50,71
totales	56464	20673	3525	24198	42,86

2.5.1 Sensibilidad y Especificidad

La Tabla 47 muestra la sensibilidad total es del 48.17% y la especificidad del 58.29% que están por debajo de los estándares aceptados por los cardiólogos³⁷ que son del 85% tanto para la sensibilidad como para la especificidad.

³⁷ Dr. Ángel María Chaves Neira, Cardiólogo – Electrofisiólogo. Fundación Cardiovascular de Colombia

* Dra. Angélica María Camargo Cerón. Médico Cirujano. Fundación Cardiovascular de Colombia

Tabla 47 Resultados de Sensibilidad y Especificidad del sistema utilizado

Record	Total latidos	FP (latidos)	FN (latidos)	Latidos sanos	Latidos enfermos	Sensibilidad %	Especificidad %
100	2273	326	0	2272	1	100,00	85,65
101	1865	262	0	1863	2	100,00	85,94
103	2084	468	0	2084	0	0,00	77,54
104	2229	347	1	2209	20	95,00	84,29
105	2572	362	3	2526	46	93,48	85,67
106	2027	588	239	1507	520	54,04	60,98
119	1987	625	249	1543	444	43,92	59,49
122	2476	1051	0	2476	0	0,00	57,55
123	1518	956	0	1515	3	100,00	36,90
124	1619	1058	3	1562	57	94,74	32,27
210	2650	897	83	2445	205	59,51	63,31
212	2748	1410	0	2748	0	0,00	48,69
213	3251	1261	264	2669	582	54,64	52,75
214	2262	1015	165	2003	259	36,29	49,33
215	3363	1206	0	3198	165	100,00	62,29
217	2208	1053	52	2046	162	67,90	48,53
220	2048	1057	0	2048	0	0,00	48,39
221	2427	0	1481	0	2427	38,98	0,00
222	2484	1476	70	2271	213	67,14	35,01
223	2605	1327	268	2118	487	44,97	37,35
228	2053	846	145	1691	362	59,94	49,97
232	1780	784	0	1779	1	100,00	55,93
233	3079	902	502	2237	842	40,38	59,68
234	2753	1396	0	2750	3	100,00	49,24
totales	56361	20673	3525	49560	6801	48,17	58,29

2.6 Reentrenamiento de la Red

Para solucionar problemas que se presentan cuando la red neuronal no reconozca latidos normales, se procede de la siguiente manera: primero se toman todos los patrones temporales y frecuenciales de los latidos que no identifica como normales y se añaden a la matriz de patrones (matriz P) ya establecida para de nuevo entrenar la red neuronal para queden identificados y reconocidos estos nuevos patrones.

3. DESCRIPCIÓN DEL SOFTWARE EN LABVIEW

Se diseñó un sistema automático haciendo uso del lenguaje de programación LabVIEW³⁸ el cual facilitó la implementación de un sistema inteligente para la detección y clasificación en el análisis morfológico de señales electrocardiográficas.

3.1 Electrocardioscopio Virtual

Se construyó un Electrocardioscopio Virtual³⁹ capaz de adquirir (ya sea desde una base de datos o una tarjeta de adquisición de datos), procesar y desplegar los resultados de las señales electrocardiográficas en tiempo real.

En la figura 42 se muestra el Electrocardioscopio Virtual⁴⁰. El panel frontal⁴¹ del instrumento creado se ilustra en la Figura 42. Se distinguen dos indicadores para despliegue de las señales resultantes del proceso diseñado a saber:

- 1) Señal electrocardiográfica (extraída de la base de datos de arritmias);
- 2) Espectro de la señal electrocardiográfica.

³⁸ (*Laboratory Virtual Instrument Engineering Workbench*), uno de los más difundidos para aplicaciones de instrumentación virtual, y que está basado en el lenguaje gráfico de programación G para facilitar la interacción sistema-usuario, y orientado particularmente a la adquisición de datos.

³⁹ El *instrumento virtual* queda definido entonces como el conjunto de software y hardware que agregado a una PC permite a los usuarios interactuar con la computadora como si se estuviera utilizando un instrumento electrónico hecho a medida.

(Alvarado, 1997: www.geocities.com/SiliconValley/Bay/2664/referenci.html)

⁴⁰ Este programa fue desarrollado en LabVIEW 6.0 adquirido por la Universidad como apoyo y fortalecimiento de líneas de investigación y enseñanza en las áreas de Ingeniería Eléctrica y Electrónica.

⁴¹ Una de las tres partes que conforman la configuración de un instrumento virtual, ver Anexo J.

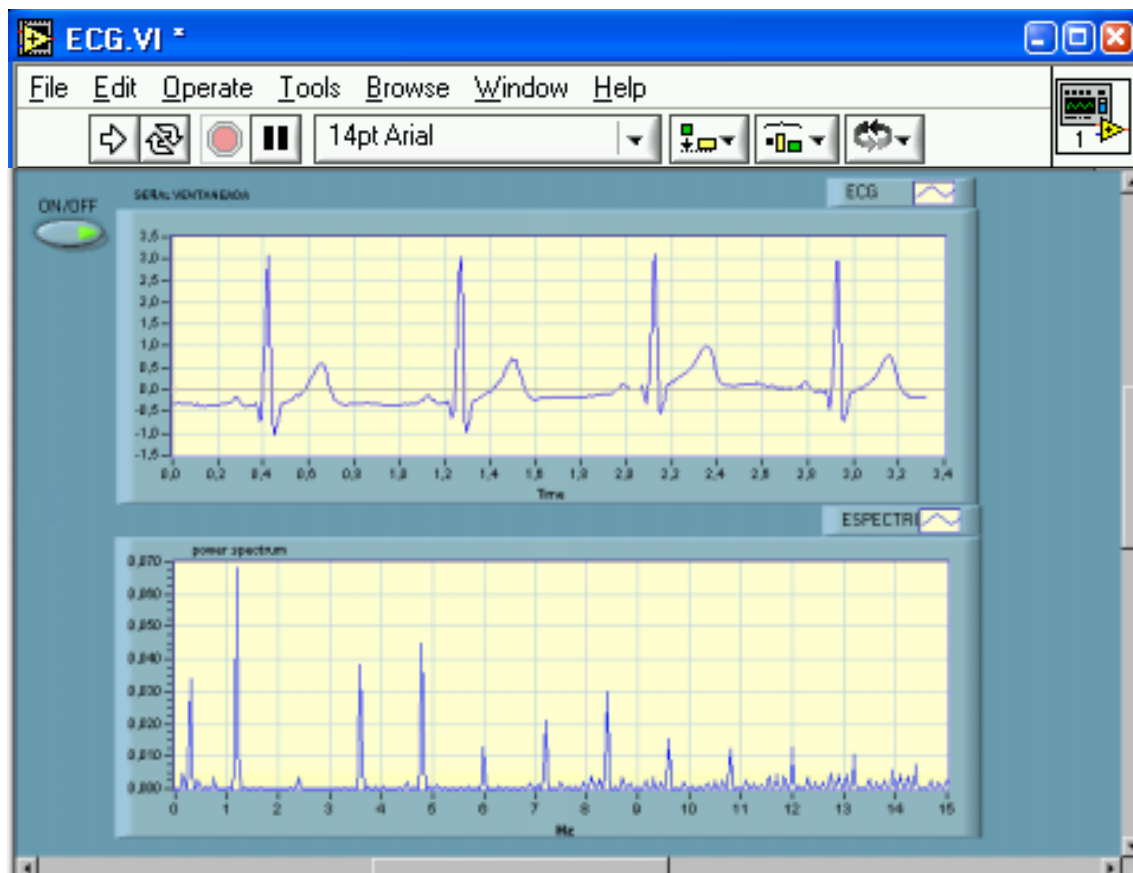


Figura 34. Panel frontal del Electrocardioscopio Virtual

El panel dispone también de un botón de encendido/apagado para iniciar el proceso continuo de captura y despliegue del ECG, y el cálculo y despliegue de las señales resultantes del proceso indicado.

La Figura 43 muestra el código gráfico utilizado en la configuración del Electrocardioscopio. En el diagrama en bloques* se distinguen los módulos⁴² componentes, cuya asociación da como resultado el instrumento de la Figura 42.

^{*42} Los módulos son la asociación de objetos, con las cuales se puede programar gráficamente en el lenguaje G

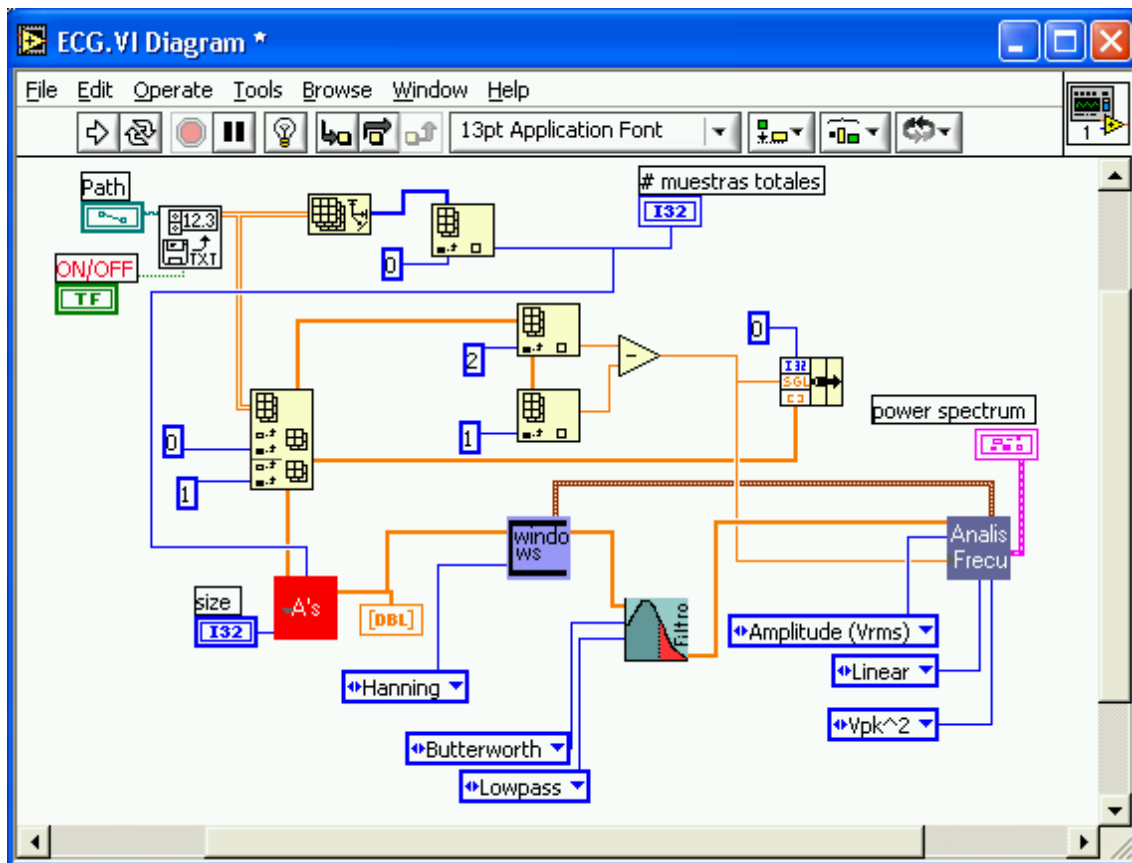


Figura 35. Código gráfico del instrumento

De esta manera se describirán estos módulos y sub-módulos haciendo una presentación básica de éstos, con los pasos que se siguieron para el procesamiento de las señales cardiacas (filtrado y ventaneo) hasta la presentación de los datos de forma grafica y el despliegue de los resultados (extracción de características o patrones temporales y frecuenciales de la señal ECG que van a ser introducidos en una red neuronal, como la salida o respuesta que arroja la misma red en el reconocimiento de las arritmias).

3.2 Procesamiento de la señal ECG

LabVIEW es un *software* que ofrece herramientas fuertes para la adecuación (filtrado y ventaneo), el análisis frecuencial y estadístico de todo tipo de señales admisibles ya sea que se lean de archivos previamente guardados en una base de datos o provenientes de la tarjeta de adquisición de datos.

De este modo, se pretende que el Electrocardioscopio Virtual, permita la visualización de la señales que se encuentran en una base de datos y así aprovechar todas las bondades de *LabVIEW* en cuanto al análisis en el dominio del tiempo y frecuencia, en la extracción de todos los patrones (o características) que sean necesarios para ser introducidos en una red neuronal (por medio de un *script* hecho en *Matlab*⁴³).

3.2.1 Ventaneo de la señal ECG

Uno de los primeros pasos que se debe hacer en la adecuación de la señal ECG es el ventaneo, todo esto debido a que al hacer ventaneo en el dominio del tiempo no se toman ciclos enteros de la señal, entonces se presenta dispersión o fugas del espectro de la señal; por eso es necesario hacer un ventaneo (en frecuencia) para suavizar el espectro frecuencial donde se presentan dichas discontinuidades. Con LabVIEW esta herramienta de ventaneo permite seleccionar ventanas, ya que algunas son más aconsejables que otras dependiendo del aspecto más crítico a analizar en el espectro. Las ventanas disponibles son: Rectangular, *Hanning*, *Hamming*, *Blackman-Harris*, *Exact Blackman*, *Blackman*, *Flat Top*, Cuatro Términos *Blackman-Harris*, Siete Términos *Blackman-Harris*.

En la figura 44 puede observarse en el Electrocardioscopio Virtual (panel frontal), como el control de entrada “**Ventana**” selecciona la ventana *Hamming*, de igual

⁴³ La versión LabVIEW 6.0 presenta una herramienta denominada *Script* que permite alternar procesamiento con Matlab (tomado de *Measurement and Automation, Catalog 2000*). Este *Script* llama a Matlab desde LabVIEW, él prueba o simula la red neuronal.

forma se selecciona con el control de entrada “No. ciclos”, cuantos ciclos de la señal se quieren analizar; además se ilustra que se han seleccionado “**Cuatro ciclos**” (máximo ocho) de la señal extraída de la base de datos conformada previamente (ver figura 42). La selección del número de ciclos hace que el programa identifique los picos (complejo QRS), calcule la distancia entre dos o tres picos consecutivos, y extraiga puntos o muestras entre dichos picos, de esta forma se garantiza que se vean ventanas indexadas en el tiempo de toda la señal original⁴⁴, de acuerdo al número de ciclos que se desee ver, como se puede apreciar en el indicador que despliega la señal ECG ventaneada (ver figura 44).



Figura 36. Panel frontal del Electrocardioscopio Virtual
Señal ECG Ventaneada

⁴⁴ Archivo proveniente de la base de datos del *MIT-BIH Normal Sinus Rhythm Database*, www.physionet.org

En el panel frontal (figura 44) aparece también el control “**clase de RN**” para seleccionar el tipo de red neuronal con el cual se desea hacer el reconocimiento de las siete arritmias más conocidas; en este caso se ve ilustrado que se ha seleccionado Redes de Base Radial RBF⁴⁵, pero se habría podido elegir también una Red *Backpropagation*, las cuales son las arquitecturas de red implementadas en este proyecto⁴⁶.

La Figura 45 muestra el módulo o *sub-vi* utilizado en código gráfico (o diagrama en bloques) del electrocardioscopio virtual para realizar el ventaneo de la señal ECG. Aquí las entradas son la señal ECG (señal ventaneada que puede ser de 4 u 8 ciclos cardiacos)⁴⁷ y el control de ventana (*Hanning*, *Hamming*, etc.) ya antes descrito; las salidas son *windows constants* que contiene constantes de la ventana seleccionada y la señal ventaneada propiamente dicha.




Figura 37. Módulo windows.vi (Ventaneo)

3.2.2 Filtrado de la señal ECG

El siguiente paso es el filtrado para reducción del ruido, en este caso, el ruido presente en la señal ECG proviene de la base datos del MIT debido a ruido generado por los propios aparatos electrónicos destinados a la adquisición (ruido térmico), y ruido generado por interferencia de la red (frecuencia de 60Hz).

⁴⁵ En el anexo K. se presentan las Redes Neuronales más conocidas la estructura de red, regla de aprendizaje, procedimiento básico para entrenar la red, resumen del algoritmo de cada una de estas redes.

⁴⁶ En el anexo K. se hace un análisis comparativo de estas dos tipos de redes neuronales.

⁴⁷ con aproximadamente 411 o 836 muestras respectivamente

Con LabVIEW, esta herramienta de filtrado permite utilizar todo tipo de filtros pasa bajos, pasa altos, banda de paso y banda de rechazo y además la selección del algoritmo utilizado para su cálculo (*Chebyshev*, *Butterworth*, *Equi-ripple*, *Bessel*, *Elíptico*).



Figura 38. Panel frontal del Electrocardioscopio Virtual
Controles de filtrado

En la figura 46 se puede observar el Electrocardioscopio Virtual (panel frontal) cómo en el control de entrada “**Filtro**” permite seleccionar el algoritmo “*Butterworth*”; de la misma forma con los controles de entrada “tipo de filtro” y “**orden**” se selecciona el filtro “**lowpass**” y el orden “5” del filtro.

En este proyecto se utilizó un filtro pasa bajos, con una frecuencia de corte de 100 Hz⁴⁸, especificado el valor en el control “**Frecuencia de corte baja**

⁴⁸Debido a que el ancho de banda en la distribución espectral de la señal ECG, es aproximadamente de 125Hz, se toma el corte en 100Hz, que se cree lo bastante aceptable, considerando que ahí en adelante no son muy significativas sus componentes espectrales.

Los demás controles como “**Frecuencia de corte alto**”, “**Frecuencia de rechazo baja**”, y “**Frecuencia de rechazo alta**” no son usados cuando se utiliza un filtro pasa bajos, pero se deja en el anexo F sus especificaciones al introducir los valores de cortes de frecuencia, según la aplicación o el tipo de filtro escogido.

Por último el control “**Fs**” que representa la frecuencia de muestreo es un parámetro de suma importancia, para que los valores de frecuencia de corte del filtro tengan un correcto escalamiento en frecuencia. El valor de Fs de entrada al filtro debe ser igual al utilizado para la señal que se adquirió⁴⁹, debido a lo anterior éste parámetro se deja como un indicador que muestra en la parte controles de filtrado la Fs con la que se digitalizó la señal.

La Figura 47 muestra el módulo o *sub-vi* utilizado en código gráfico (o diagrama en bloques) del Electrocardioscopio Virtual para realizar el filtrado. Aquí las entradas son la señal ECG ventaneada y los controles de filtrado; la salida es la señal out o filtrada.




Figura 39. Módulo Filtro.vi

En este momento ya se tiene la señal preparada para la obtención de su espectro en frecuencia. A continuación se presenta la herramienta (*sub-vi* o módulo) disponible para éste análisis:

⁴⁹ En el panel frontal se especifica una frecuencia de muestreo de 250 Hz, que es una frecuencia típica para la adquisición de este tipo de señales.

3.2.3 Obtención del Espectro de la señal ECG

Desde el punto de vista del procesamiento de señales hay que tener en cuenta el contenido frecuencial del ECG. El ancho de banda de la señal electrocardiográfica normal es aproximadamente de unos 125 Hz, con la distribución espectral mostrada en la figura 48, donde se puede observar cómo las componentes por encima de los 30 Hz no son muy significativas.

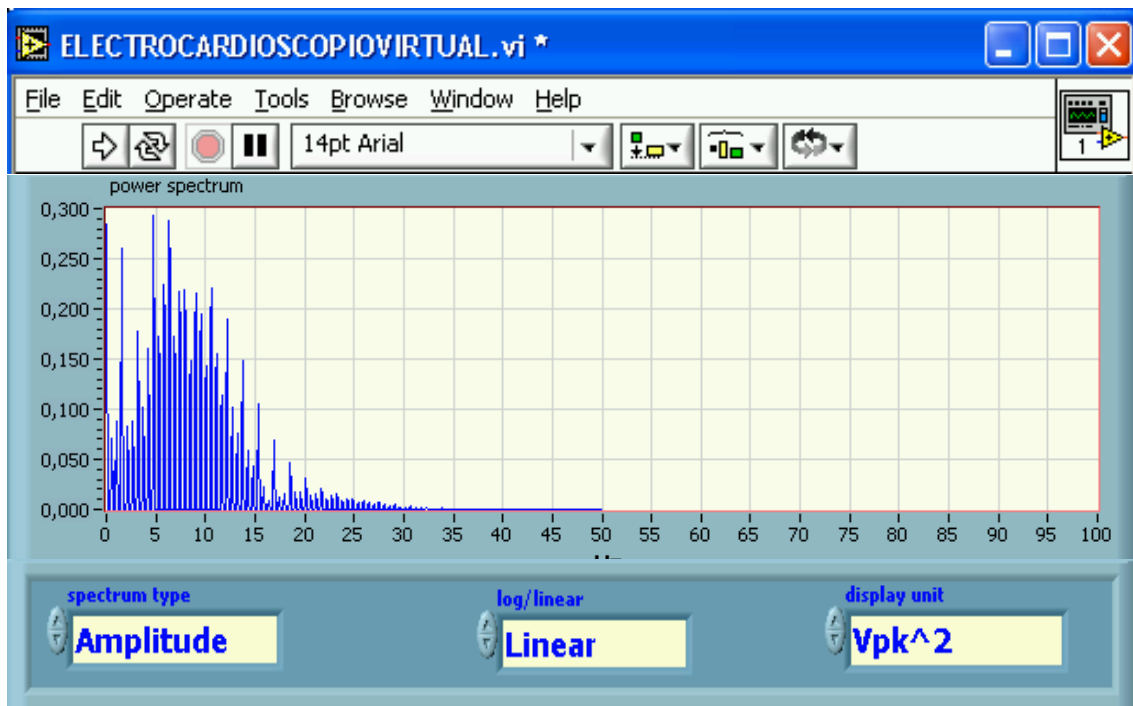


Figura 40. Panel frontal del Electrocardioscopio Virtual
Distribución frecuencia de una señal ECG

Puede observarse en la figura 48, panel frontal del Electrocardioscopio Virtual, cómo el control de entrada “**spectrum type**” selecciona el tipo de espectro que se desee ver como: **Power, Gain, Amplitude**. Con el control de entrada “**display unit**” se presentan las amplitudes del espectro en diferentes unidades: **Vrms**,

V_{rms}^2 , V_p , V_p^2 , V_{rms}/\sqrt{Hz} , V_{rms}^2/Hz , V_p/\sqrt{Hz} , V_p^2/Hz ; y también se puede hacer el escalamiento del eje Y (lineal, logarítmico) con el control “**Log/Lineal**”.

La Figura 49 muestra el módulo o *sub-vi* utilizado en el código gráfico (o diagrama en bloques) del Electrocardioscopio Virtual que realiza el análisis frecuencial; este subvi permite determinar el espectro en frecuencia de la señal ECG, con sus respectivos cálculos: desviación estándar, mediana, Frecuencia Fundamental y ancho de banda (del espectro frecuencial de la señal ECG correspondiente al 95% de la energía).

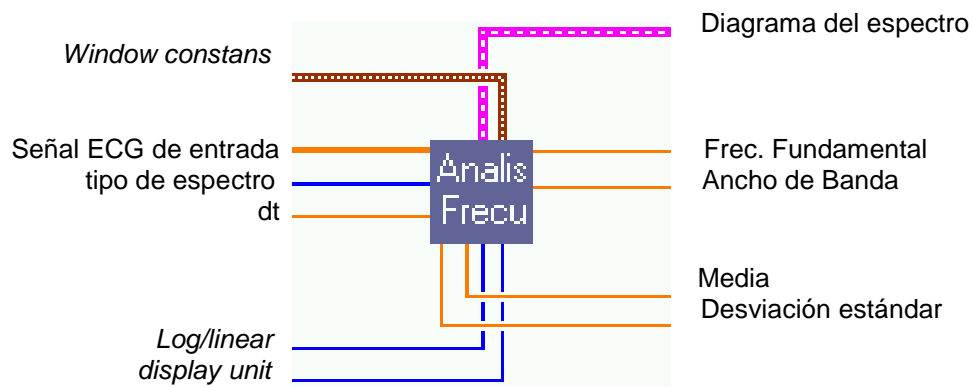


Figura 41. Módulo Análisis Frecuencia.vi

3.2.4 Otros módulos y sub-módulos

Hay que mencionar otros módulos o *sub-vi* del Electrocardioscopio Virtual (componentes del diagrama de bloques o código del instrumento) con los cuales se pudo obtener otros parámetros que se necesitaron en este instrumento virtual. Seguidamente se realiza una descripción general del funcionamiento de cada subvi (o sub-módulo), especificando sus entradas y salidas.

3.2.4.1 *Subvi* NoZero.vi

En la figura 50, se presenta el *sub-vi* (o sub-módulo), el cual permite calcular el número de cruces por cero de la señal ECG. Aquí la única entrada de este *sub-vi* es la señal ECG y la salida es el número de cruces por cero de dicha señal.




Figura 42. Módulo No. Zero.vi

3.2.4.2 *Subvi* Estadística tiempo.vi

La figura 51, presenta el *sub-vi* (o sub-módulo), que permite calcular parámetros estadísticos en el dominio del tiempo; la entrada de este *sub-vi* es la señal ECG y sus salidas son: la mediana, el valor rms, y la varianza de la señal ECG.



Figura 43. Módulo Estadística tiempo.vi

3.2.4.3 *Subvi* Parseval.vi

Este *sub-vi* (o sub-módulo) facilita el cálculo de la energía (señal ECG) en el dominio del tiempo (Teorema de Parseval). La entrada de este *sub-vi* es la señal ECG y las salidas son: los cálculos de la energía de la señal ECG en el dominio del tiempo y la frecuencia⁵⁰ (ver la figura 52).

⁵⁰ Es de anotar que estos dos cálculos van a ser idénticos, ya que la energía de la señal es la misma tanto para el dominio del tiempo como en el dominio de la frecuencia, según el teorema de Parseval por lo tanto se puede tomar cualquiera de los dos resultados.



Figura 44. Módulo Parseval.vi

3.2.4.4 Subvi AR.vi

Se presenta el *sub-vi* (o sub-módulo), en el que se pueden obtener coeficientes del modelo AR de orden 16. La entrada de este *sub-vi* es la señal ECG y las salidas son: los primeros 4 coeficientes del modelo AR y el vector de correlación (ver figura 53).




Figura 45. Módulo AR.vi

3.3 Conformación de los Patrones temporales y frecuenciales

Una vez ventaneada, filtrada y obtenido el espectro de frecuencia de la señal ECG y con la obtención de otras características, se procede a conformar los 14 patrones⁵¹ en el dominio del tiempo⁵² y frecuencia, que se van a introducir en una red neuronal; donde se tiene dos fases, una de aprendizaje en la cual se ha entrenado la red previamente usando *Matlab* y otra de funcionamiento donde el instrumento virtual interactúa con la red, suministrando datos de prueba (nuevos patrones a reconocer).

⁵¹ Como puede verse en la tabla 43, capítulo 2, numeral 2.1

⁵² En el dominio del tiempo como: número de cruces por cero, varianza, mediana, valor rms, valor de la energía y coeficientes AR de la señal ECG.

La figura 54 presenta todos los subvi (diagrama de bloques del electrocardioscopio virtual), que permiten la extracción de las características o patrones de la señal ECG. Estos patrones luego son organizados en un arreglo (*build array*) que los concatena dentro de un vector de una sola dimensión.

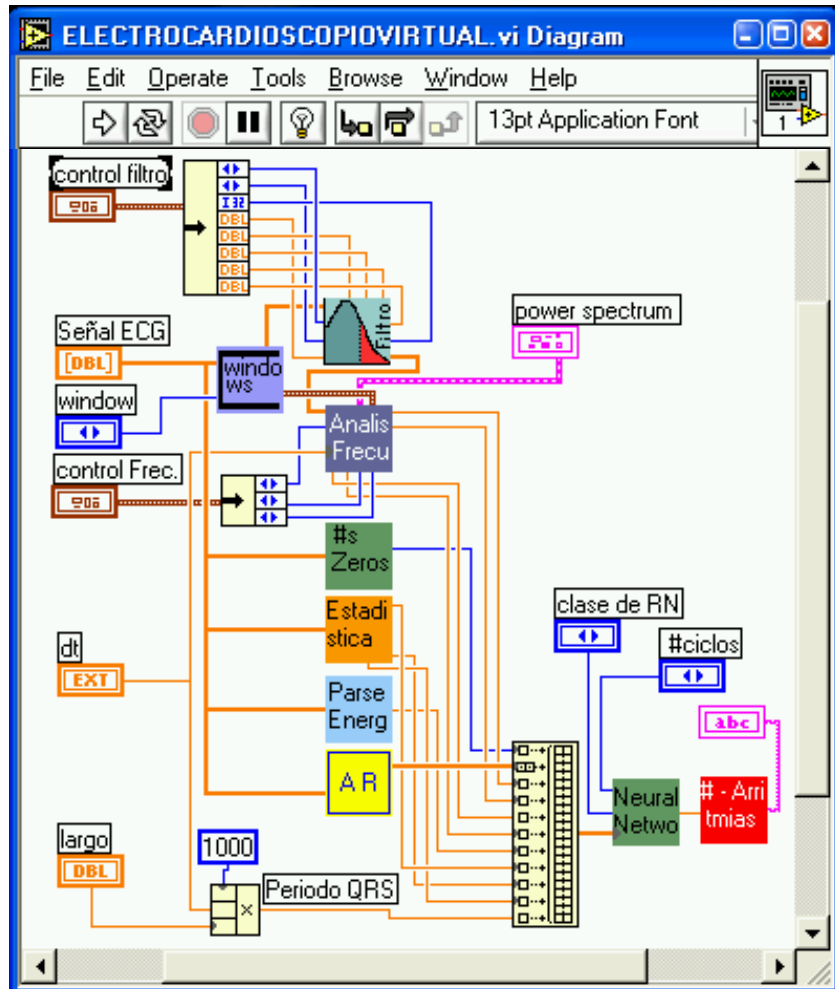


Figura 46. Código gráfico del Electrocardioscopio Virtual

Este vector de 14 patrones es luego introducido en subvi (figura 55) que va a realizar la tarea más importante de este instrumento virtual, en el uso de una red neuronal que va a reconocer y clasificar estos patrones de entrada dentro de las

siete arritmias a identificar. Este *subvi* implementa un *script* que permite alternar el procesamiento con *Matlab*⁵³, en el cual se pueda simular la red.

El *subvi* (módulo) que realiza la implementación del sistema inteligente es el ilustrado en la figura 55 cuyos controles de entradas son: “**número de ciclos**”⁵⁴ a ser analizados (tres hasta ocho ciclos de la señal ECG), la “**clase de RN**”^{*} que corresponde al tipo de red neuronal que desee seleccionar (Redes de Base Radial o *Red Backpropagation*) para el reconocimiento; y el “**vector patrón**”, que puede pertenecer a cualquiera de los 2271 que conforman la tabla 43. La salida del *subvi* que es el “**Tipo de patrón**” que corresponde a la clasificación que realiza la red de acuerdo al vector patrón que se presente a la entrada.




Figura 47. Módulo *Neural Network.vi*

Hasta ahora se ha presentado el funcionamiento general del Electrocardioscopio Virtual con la extracción de los 14 patrones como se aprecia en la tabla 43 donde se crea una super matriz de patrones.

De aquí en adelante se centra el estudio en el entrenamiento y simulación de la red neuronal con base en esta matriz (matriz P ecuación 8 capítulo 2), explorando diferentes configuraciones hasta encontrar la que obtenga el mejor desempeño, y se compararan los resultados con otro tipo de red.

⁵³ Utilización del Toolbox de Redes Neuronales de Matlab 5.3. La versión LabVIEW 6.0 presenta una herramienta denominada Script que permite alternar procesamiento con Matlab (tomado de *Measurement and Automation, Catalog 2000*).

^{* 54} Ya mencionados en los controles de entrada del modulo ventaneo de la señal ECG numeral 3.2.1

4. ANÁLISIS DE DESEMPEÑO DE LA RED NEURONAL

4.1 Selección de los datos de Entrenamiento y Validación

Se organizaron los datos en dos grupos, el 80% para el *set* de entrenamiento y el 20% restante para el *set* de validación; esto corresponde a 1816 datos para entrenamiento y 455 datos para la validación, de los 2271 datos disponibles.

4.2 Configuración de la Red *Backpropagation* con el mejor desempeño

Luego se va a determinar el número de neuronas de cada capa con las cuales se alcanza el rendimiento óptimo de la red; para esto se procede a entrenar la red con diversas configuraciones para un número diferente de neuronas en cada capa y observando el mejor desempeño de la red tanto en la etapa de entrenamiento como en la etapa de validación.

Las posibles combinaciones que se estudiaron para el número de neuronas de la capa de entrada (n_e) y oculta (n_o) fueron las siguientes:

$$n_e = 7, 14, 21, 28$$

$$n_o = 8, 16, 24, 32$$

Las posibles 16 combinaciones entre n_e y n_o se entrenaron 5 veces cada una, lo anterior para obtener un promedio de los errores calculados en el comportamiento de red para dichas configuraciones, se analizó en total 80 redes.

Para evaluar el buen desempeño de la red es necesario comparar los valores reales y los estimados por la red con el fin de calcular el error en la simulación, para ello se ejecutaron los siguientes comandos en *Matlab*.

```
e=abs(T-y) %S=size(e,2) Error:salidas deseadas-salidas obtenidas
ecm=mse(e) %ecm=sum(e.^2)/S Error Cuadrático medio
eap=mae(e) %eap=sum(abs(e))/S Error Absoluto Promedio
Dmx=max(e) %Desviación Máxima
```

4.2.1 Análisis en la Fase de Entrenamiento y Validación

Después del proceso de entrenamiento los pesos de las conexiones en la red neuronal quedan fijos. Como paso siguiente se debe comprobar si la red neuronal puede resolver nuevos problemas del tipo general, para los que ha sido entrenada. Por lo tanto, con el propósito de validar la red neuronal se requiere de otro conjunto de datos, denominado conjunto de validación o *testeo*.

Cada ejemplo del conjunto de evaluación contiene los valores de las variables de entrada, con su correspondiente solución tomada; pero ahora esta solución no le es otorgada a la red neuronal. Luego se compara la solución calculada para cada ejemplo de validación con la solución conocida.

Se realizaron 80 simulaciones tanto para evaluar la fase de entrenamiento como la posterior validación de la red para cada combinación posible de neuronas de entrada y neuronas ocultas.

En las tablas 53 y figura 56 se presenta el error cuadrático medio (*mse*), estos son los resultados obtenidos luego del proceso de simulación. Allí puede verse para la fase de entrenamiento una disminución en el error a medida que aumenta el

número de neuronas de entrada. No puede decirse lo mismo para la fase de validación, pues no se observa un comportamiento igual.

Los mejores resultados se obtuvieron en la fase de entrenamiento con un error cuadrático medio (*mse*) de 0,0004 para una configuración de red de 28 neuronas en la capa de entrada y 32 neuronas en la capa oculta (28-32-1). El mejor desempeño para la fase de validación fue con la configuración de red de 14 neuronas de la capa de entrada y 24 neuronas en la capa oculta (14-24-1), con un error cuadrático medio (*mse*) de 0.0058 (ver tabla 53).

En la Tabla 54 y 55 se muestran los resultados del error absoluto promedio y la desviación máxima luego de simular la red para cada configuración de neuronas de entrada utilizada. Puede observarse que para la fase de entrenamiento el error absoluto promedio como la desviación máxima, tienden a disminuir a medida que aumentan las neuronas de entrada, de igual forma como ocurre en el caso del error cuadrático promedio. En forma muy distinta se desempeña la red en la fase de validación, donde se ve que el mínimo error se encuentra con la configuración de 14 neuronas de entrada.

Los mejores resultados (tabla 54) se obtuvieron de nuevo en la fase de entrenamiento con un error absoluto promedio (*mae*) de 0.0118 para una configuración de red de 28 neuronas en la capa de entrada y 32 neuronas en la capa oculta (28-32-1); el mínimo error absoluto promedio (*mae*) para la etapa de validación fue de 0.0433 con una configuración de red de 14 neuronas en la capa de entrada y 24 neuronas en la capa oculta (14-24-1).

Para la tabla 55, el menor error de desviación máxima (*Dmx*) se logró en la fase de validación con un valor de 0.0372 para una configuración de red de 14 neuronas en la capa de entrada y 16 neuronas en la capa oculta (14-16-1); y no en la fase de entrenamiento como se esperaría, con un valor mínimo de 0.0967 con una configuración de 28 neuronas en la capa de entrada y 32 neuronas en la capa oculta (28-32-1).

Tabla 48. Resultados del Error Cuadrático Medio para el proceso de simulación utilizando fase de entrenamiento y validación.⁵⁵

no \ ne	7		14		21		28	
	ENT	VAL	ENT	VAL	ENT	VAL	ENT	VAL
8	0.2241	0.3071	0.0335	0.2216	0.0601	0.2552	0.0240	0.2655
16	0.0303	0.2085	0.0033	0.0161	0.0031	0.1565	0.0014	0.0794
24	0.0052	0.1394	0.0016	0.0058	0.0006	0.0313	0.0013	0.6634
32	0.0106	0.2376	0.0008	0.0399	0.0020	0.1586	0.0004	0.1655

Tabla 49. Resultados del Error Absoluto Promedio para el proceso de simulación utilizando fase de entrenamiento y validación.

no \ ne	7		14		21		28	
	ENT	VAL	ENT	VAL	ENT	VAL	ENT	VAL
8	0.2560	0.4067	0.1021	0.3701	0.1429	0.3868	0.0950	0.2994
16	0.1104	0.2289	0.0340	0.0620	0.0297	0.3176	0.0208	0.1053
24	0.0447	0.2585	0.0226	0.0433	0.0151	0.1239	0.0213	0.5916
32	0.0590	0.2480	0.0173	0.1350	0.0266	0.1903	0.0118	0.2940

Tabla 50. Resultados de Desviación Máxima para el proceso de simulación utilizando fase de entrenamiento y validación.

no \ ne	7		14		21		28	
	ENT	VAL	ENT	VAL	ENT	VAL	ENT	VAL
8	1.6058	0.5753	0.9201	0.2765	0.9926	0.1948	0.8410	0.4551
16	0.6002	0.4756	0.2644	0.0372	0.2548	0.2263	0.1593	0.2012
24	0.3109	0.2085	0.1889	0.0668	0.1062	0.0886	0.1417	0.4457
32	0.3930	0.0923	0.1038	0.1105	0.1614	0.3102	0.0967	0.2351

⁵⁵ Los resultados en color azul corresponden a los mejores resultados obtenidos.




Figura 48. Error cuadrático medio para la combinación de neuronas de entrada y neuronas ocultas utilizadas en la fase de entrenamiento y validación.

4.2.2 Inclusión de una nueva capa oculta

Debido a la complejidad de los patrones de entrada a clasificar por la red y a la poca generalización (su facilidad para entregar una salida satisfactoria a entradas que el sistema nunca vió en su fase de entrenamiento), se ve la necesidad de incorporar una capa oculta, para que de esta manera la red pueda solucionar correctamente el problema, pues una red de estas características (dos capas ocultas y una de salida) está en capacidad de generar regiones de decisión arbitrariamente complejas.

En la segunda capa oculta fue implementada la función de activación *sigmoide tangencial* (*TANSIG*) garantizando la tendencia a aumentar la extensión de la función de activación de la primera capa oculta, quedando la configuración de la red de la siguiente manera: capa de entrada con función de activación *sigmoide tangencial* (*TANSIG*), primera capa oculta con función de activación *sigmoide tangencial* (*TANSIG*), segunda capa oculta con función de activación *sigmoide tangencial* (*TANSIG*), y la capa de salida con función de activación lineal (*PURELIN*). Aunque pueda parecer que se aumento la complejidad de la red, se logro disminuir significativamente el numero de épocas y por lo tanto el tiempo de entrenamiento.

En la tabla 56 se muestran los diferentes errores con los que se evaluó el desempeño de la red con dos capas ocultas. Para cada configuración de red, se entrenó 7 veces cada una; obteniendo un promedio de los errores calculados; se analizaron en total 91 redes.

En la Tabla 56 y figura 57 se presenta el error cuadrático medio (*mse*), resultados luego del proceso de simulación. Allí puede verse que el mejor desempeño de la red para la fase de entrenamiento ocurre con una configuración de 21-32-24-1, con un error cuadrático medio de 0.00009, el resultado en la etapa de validación

que tuvo mejor desempeño fue con una configuración de red de 28-24-16-1, con un error cuadrático medio de 0.0005.

Tabla 51. Resultados del Error para el proceso de simulación con la combinación de dos capas ocultas de neuronas y una de salida utilizando fase de entrenamiento y validación.⁵⁶

CONFIGURACIÓN DE LA RED	Error Cuadrático Medio		Error Absoluto Promedio		Desviación Máxima	
	ENT	VAL	ENT	VAL	ENT	VAL
7-24-16-1	0.00144	0.1975	0.0214	0.2764	0.1607	0.3545
14-21-24-1	0.00044	0.1546	0.0117	0.2232	0.0879	0.1386
14-24-21-1	0.00021	0.1415	0.0085	0.1778	0.0660	0.0500
14-28-16-1	0.00047	0.1102	0.0130	0.2016	0.0876	0.2207
14-28-32-1	0.00016	0.2194	0.0073	0.2868	0.0551	0.1634
14-32-16-1	0.00019	0.0392	0.0074	0.0985	0.0596	0.1468
14-32-28-1	0.00020	0.1263	0.0087	0.1724	0.0536	0.1847
21-24-16-1	0.00032	0.0897	0.0101	0.1502	0.0646	0.0530
21-28-32-1	0.00011	0.0633	0.0059	0.1639	0.0430	0.1564
21-32-16-1	0.00018	0.1961	0.0074	0.2987	0.0557	0.1543
21-32-24-1	0.00009	0.1363	0.0054	0.1619	0.0415	0.2797
28-24-16-1	0.00049	0.0005	0.0123	0.0123	0.0851	0.0851
28-32-16-1	0.00011	0.2397	0.0060	0.2965	0.0442	0.3168

En la figura 58 se muestra el error absoluto promedio (*mae*) obtenido para cada configuración de neuronas; el menor error absoluto promedio se logró con la configuración de red 21-32-24-1; siendo de 0.0054 para la fase de entrenamiento y 0.0123 para la fase de validación, con una configuración de red de 28-24-16-1 (ver tabla 56).

En la figura 59, el menor error de desviación máxima (*Dmx*) se logró en la fase de entrenamiento; siendo de 0.0415 para una configuración de red de 21-32-24-1 y

⁵⁶ Los resultados en color azul corresponden a los mejores resultados obtenidos.

de 0.050 para la fase de validación, con una configuración de red de 14-24-21-1 (ver tabla 56).

Con la inclusión de una nueva capa oculta la red se desempeñó con errores menores a los alcanzados con una sola capa oculta, reduciendo el tiempo de entrenamiento, con ello el número de épocas con las que se entrenaba la red, del mismo modo se obtienen mejores resultados ante la generalización.

Es de anotar que para las configuraciones de red estudiadas, que si bien los resultados para la fase de entrenamiento eran muy buenos, los resultados para la fase de validación son todo lo contrario, si se obtenía una configuración con un muy buen desempeño en la fase de validación, los resultados en la fase de entrenamiento están muy lejos de ser los mejores.

4.2.3 Análisis en la fase de Entrenamiento, Validación y Prueba

Buscando un equilibrio entre los resultados de entrenamiento y validación de la red neuronal, en la cual no haya mucha discrepancia de la red ante el incremento o disminución en el error con las diferentes configuraciones implementadas en estas dos fases; se procede a incluir nuevos datos de entrada distintos a los de entrenamiento ó validación. Así de esta manera se hace una nueva distribución de los datos para formar un nuevo *set* que permita estudiar el funcionamiento de la red ante datos que nunca vió en su fase de aprendizaje. Este nuevo *set* de datos es denominado *set* de prueba.




Figura 49. Error cuadrático medio para la combinación de dos capas ocultas de neuronas y una de salida en la fase de entrenamiento y validación.




Figura 50. Error Absoluto Promedio para la combinación de dos capas ocultas de neuronas y una de salida en la fase de entrenamiento y validación.

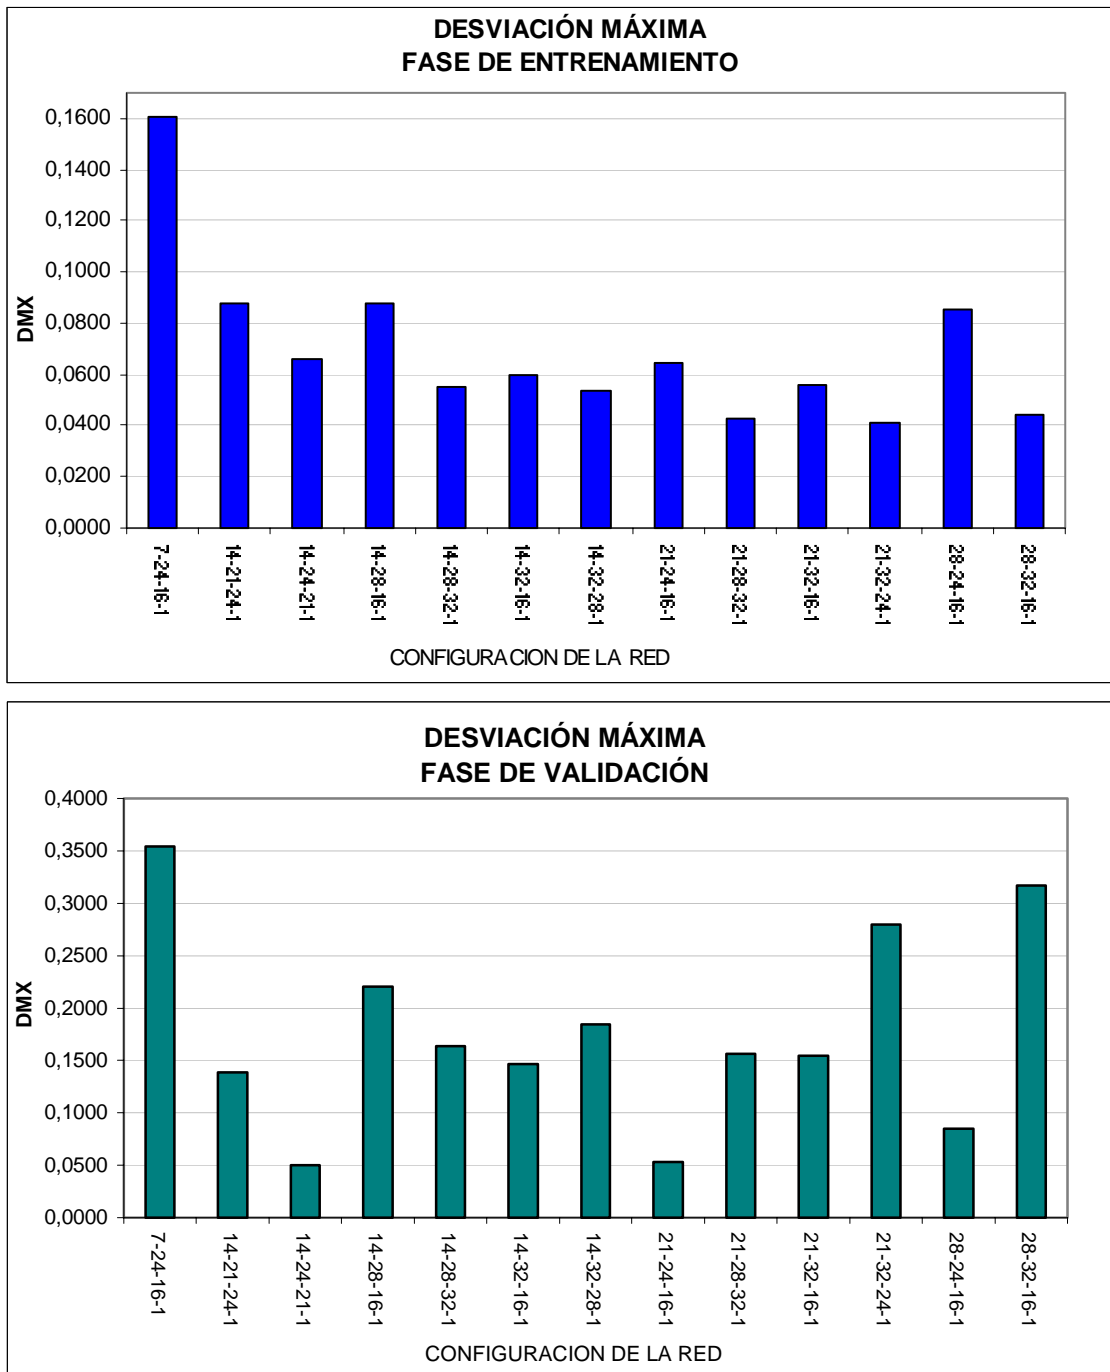


Figura 51. Desviación máxima para la combinación de dos capas ocultas de neuronas y una de salida en la fase de entrenamiento y validación

Así mismo se distribuyen los datos de entrada en 3 nuevos grupos y se determinó utilizar 2271 datos para el *set* de entrenamiento, 227 para el *set* de validación y 227 para el *set* de prueba.

Considerando que la mejor configuración para la fase de entrenamiento es 21-32-24-1 y la mejor configuración para la fase de validación es 28-24-16-1, según la tabla 6 (resaltados en azul). Con base en estas dos configuraciones, junto con otras cuatro posibles combinaciones donde se obtuvo buenos resultados, se procedió a realizar las respectivas simulaciones⁵⁷ en busca de la configuración de red que mejor se desempeñe tanto en la fase de entrenamiento, como de validación.

La conformación del *set* de prueba obedece al propósito de observar como se comporta la red ante la variación de los errores en las etapas de entrenamiento y validación; además de este *set* de prueba, sus resultados no son tenidos en cuenta para la selección de la mejor configuración.

La figura 60 muestra la tendencia del error cuadrático medio de la red, para las tres etapas (entrenamiento, validación y prueba), la cual sigue una trayectoria de aumento o disminución muy similar para cada una de ellas, a medida que se explora cada una de las seis configuraciones de red. Allí puede verse los mejores resultados obtenidos con la configuración 21-32-24-1 tanto para la etapa de entrenamiento como validación.

⁵⁷ Para las 6 configuraciones de red seleccionadas, se simularon 7 veces cada una, obteniendo el promedio de los errores presentados en la tabla 56, se analizaron en total 42 redes.




Figura 52. Error cuadrático medio para el proceso de simulación utilizando fase de entrenamiento, validación y prueba.




Figura 53. Error absoluto promedio para el proceso de simulación utilizando fase de entrenamiento, validación y prueba

En la figura 61 se presentan los resultados del error porcentual absoluto promedio para las tres etapas. Para esta gráfica, el comportamiento del error absoluto promedio (*msa*) para la etapa de prueba sigue una trayectoria muy similar a la observada para la fase de entrenamiento, pero las tres etapas arrojan como mejor configuración 21-32-24-1, la cual tiene el mínimo error porcentual absoluto.

En la figura 62 se presenta el error de desviación máxima obtenido en cada etapa luego de la simulación. Aquí se puede apreciar que los resultados en la etapa de validación y entrenamiento están relativamente cercanos, y donde el menor error de desviación máxima se tiene de nuevo con la configuración 21-32-24-1.

En las tablas 57, 58 y 59 se muestran los errores para cada una de las configuraciones durante el proceso de simulación en la etapa de validación, entrenamiento y prueba respectivamente.




Figura 54. Error de Desviación Máxima para el proceso de simulación utilizando fase de entrenamiento, validación y prueba

Esta claro que la mejor configuración utilizando fase de entrenamiento, validación y prueba es 21-32-24-1, un resultado coherente pues para cada tipo de error la red tuvo los mejores resultados tanto para la fase de entrenamiento como validación (ver tabla 57 y 58).

Tabla 52. Errores en el proceso de simulación para la etapa de validación para las seis diferentes configuraciones de red seleccionadas utilizando fase de entrenamiento, validación y prueba.

ERRORES DE VALIDACIÓN			
CONFIGURACIÓN DE LA RED	Error Cuadrático Medio	Error Absoluto Promedio	Desviación Máxima
14-32-16-1	0,1818	0,1749	0,4911
14-28-32-1	0,2718	0,3614	0,7685
21-28-32-1	0,1550	0,1939	0,4821
21-32-24-1	0,0049	0,0391	0,0779
28-24-16-1	0,1036	0,1823	0,3609
28-32-16-1	0,0583	0,1163	0,2775

Tabla 53. Errores en el proceso de simulación para la etapa de entrenamiento para las seis diferentes configuraciones de red seleccionadas utilizando fase de entrenamiento, validación y prueba.

ERRORES DE ENTRENAMIENTO			
CONFIGURACIÓN DE LA RED	Error Cuadrático Medio	Error Absoluto Promedio	Desviación Máxima
14-32-16-1	0,000557	0,01303	0,1273
14-28-32-1	0,000186	0,00723	0,0564
21-28-32-1	0,000373	0,01034	0,0881
21-32-24-1	0,000096	0,00549	0,0539
28-24-16-1	0,000141	0,00710	0,0626
28-32-16-1	0,000238	0,00874	0,0704

Tabla 54. Errores en el proceso de simulación para la etapa de prueba para las seis diferentes configuraciones de red seleccionadas utilizando fase de entrenamiento, validación y prueba

ERRORES DE PRUEBA			
CONFIGURACIÓN DE LA RED	Error Cuadrático Medio	Error Absoluto Promedio	Desviación Máxima
14-32-16-1	0,6114	0,5336	1,1411
14-28-32-1	0,5236	0,3458	0,9019
21-28-32-1	0,4299	0,3566	0,7660
21-32-24-1	0,0591	0,1320	0,3009
28-24-16-1	0,6540	0,2757	0,8046
28-32-16-1	0,1661	0,1462	0,3461

Una vez encontrada la configuración red que tiene los mínimos errores en la etapa de entrenamiento y validación se procede a presentar el desempeño del error versus el número de épocas de entrenamiento.




Figura 55. Iteraciones vs. Error en la clasificación de los patrones para la configuración de red 21-32-24-1

Luego de varias iteraciones el error cayó por debajo de 2×10^{-5} , el desempeño del error medio cuadrático (mse) puede observarse en la figura 83.

4.3 Evaluación de desempeño de la *Red Base Radial*

Los restantes 455 valores de los patrones de entrenamiento se tomaron como valores de prueba del rendimiento de la red y se agruparon en la matriz P1, siendo T1 el vector de salidas esperadas.

```
a = sim(red,P1);      %Prueba de la red
```

En la tabla 60, se muestran los resultados obtenidos después del proceso de simulación de la red.

Tabla 55. Resultados del Error para el proceso de simulación de la red de Base Radial en la fase de entrenamiento y validación

Error Cuadrático Medio		Error Absoluto Promedio		Desviación Máxima	
ENT	VAL	ENT	VAL	ENT	VAL
2,202E-09	0,643	4,423E-06	0,2143	4,268E-04	0,4287

Puede verse en la tabla 60 como los mejores resultados obtenidos fueron en la fase de entrenamiento para las tres clases de errores evaluados; error cuadrático (*mse*), error absoluto promedio (*mae*), y desviación máxima (*Dmx*).

Pero la situación es totalmente diferente para la fase de validación, los errores son muy altos, distantes de ser óptimos.

Es claro que la red de Base Radial logra un alto desempeño clasificando patrones, esto se pone de manifiesto por los resultados obtenidos al simular la red, los

errores en la fase de entrenamiento son aun mucho mejores que los alcanzados anteriormente con la red *Backpropagation* en su mejor configuración, pero con un pobre desempeño en su fase de validación significando que tiene poca capacidad de generalización y se ve superada por la red *Backpropagation* con resultados más aceptables en su fase de validación.

CONCLUSIONES

De forma satisfactoria se creó un Electrocardioscopio Virtual⁵⁸ que lleva a cabo las siguientes tareas: visualiza las señales electrocardiográficas provenientes de una base de datos; las procesa para calcular parámetros (en tiempo y frecuencia); envía información (estos mismos parámetros) a una red neuronal artificial y recibe la respuesta que arroja la misma red para luego desplegar los resultados del reconocimiento de arritmias en tiempo real.

Se formó una base de datos de señales electrocardiográficas con 25 registros descargados de la *web*⁵⁹ que pertenece a *Arrhythmia Database* (Serie 100) del MIT (*Massachusetts Institute of Technology*). La base de datos quedó organizada de acuerdo al tipo de derivación (MLII, VI, V2, V5) con sus registros en formato *.xls con toda la información comprendida (señal + anotación). Para aportar más flexibilidad a la base de datos se confeccionaron nuevos registros como combinaciones de los ya existentes.

Se lograron extraer los 14 parámetros en dominio del tiempo y la frecuencia de las señales ECG haciendo uso de los módulos y sub-módulos (*sub.vi*) del Electrocardioscopio Virtual de forma eficiente.

En cuanto a la clasificación de las señales ECG, un parámetro a tener en cuenta es la frecuencia cardiaca (latidos/minutos o bmp) de la señal, que refleja cambios notorios en el espectro de frecuencia. Las figuras en el capítulo 1 ilustran que el corrimiento de los componentes espectrales es relativamente notorio, teniendo en cuenta que sus frecuencias fundamentales son muy cercanas. En este caso se recomienda observar otros parámetros temporales o frecuenciales que ayuden a diferenciar las señales ECG unas de otras.

⁵⁸ Haciendo uso del lenguaje de programación gráfica LabVIEW.

⁵⁹ www.physionet.org

La red neuronal se entreno utilizando la Serie 100 de la base de datos del MIT/BIH (*Arrhythmia Database*) por presentar una amplia variedad de formas de onda. De cada registro se ha seleccionado 5 minutos significativos de la señal donde aparece una anomalía (arritmia), tiempo que consideramos suficiente para la fase de entrenamiento.

Se validó el desempeño del sistema (el instrumento virtual mas la implementación de la red neuronal) con la totalidad de las señales (30 minutos) de la serie 100 *Arrhythmia Database*, obteniéndose los siguientes resultados: eficiencia del 57.14 %, sensibilidad total del 48.17% y la especificidad del 58.29%, que están por debajo de los estándares aceptados por los cardiólogos⁶⁰ que son del 85% tanto para la sensibilidad como para la especificidad.

La red neuronal artificial (RNA) se desarrolló en Matlab⁶¹, donde se escogieron dos tipos de algoritmo de red: Red *Backpropagation* y Redes de Base Radial; que se entrenaron, simularon y con los resultados obtenidos se hizo un análisis comparativo y se observó:

- En el algoritmo *Backpropagation*, no hay ningún criterio establecido para decidir la arquitectura final de la red, la elección del número de capas que la componen y el número de neuronas de cada una de ellas. Por esto se decidió primero, como un método de ensayo y error, trabajar con tres capas de neuronas. Después de explorar diferentes configuraciones se encontró que la de mejor desempeño en la fase de entrenamiento corresponde a: 28-32-1 (con funciones de activación *sigmoide tangencial (TANSIG)*; *sigmoide tangencial (TANSIG)* y lineal (*PURELIN*) para las capas de entrada, oculta o intermedia y salida respectivamente) , la cual presenta los siguientes resultados: un error cuadrático medio (*mse*) de 0,0004, un error absoluto promedio (*mae*) de 0.0118, y el menor error de desviación máxima (*Dmx*) de 0.0967.

⁶⁰ Dr. Ángel María Chaves Neira, Cardiólogo – Electrofisiólogo. Fundación Cardiovascular de Colombia

* Dra. Angélica María Camargo Cerón. Médico Cirujano. Fundación Cardiovascular de Colombia

⁶¹ Utilización del Toolbox se Redes Neuronales

- Debido a que la red *Backpropagation* de tres capas, es muy deficiente en su generalización (su facilidad para entregar una salida satisfactoria a entradas que el sistema nunca vio en su fase de entrenamiento), y que necesita de un prolongado tiempo para su fase de entrenamiento debido a la complejidad de los patrones de entrada a clasificar⁶², se optó por incluir una nueva capa oculta de neuronas; donde se exploraron diferentes configuraciones y se llegó a determinar que la configuración que presenta mejor desempeño es: 21-32-24-1 (capa de entrada con función de activación *sigmoide tangencial (TANSIG)*, primera capa oculta con función de activación *sigmoide tangencial (TANSIG)*, segunda capa oculta con función de activación *sigmoide tangencial (TANSIG)*, y la capa de salida con función de activación lineal (*PURELIN*), con los siguientes errores: error cuadrático medio (*mse*) de 0,000096, error absoluto promedio (*mae*) de 0,00549 y error de desviación máxima (*Dmx*) de 0,0539 para la fase de entrenamiento.
- La red de tipo *Backpropagation* que presenta los mejores resultados en la fase de validación es la configuración 21-32-24-1 con un error cuadrático medio (*mse*) de 0,0049, un error absoluto promedio (*mae*) de 0,0391 y un error de desviación máxima (*Dmx*) de 0,0779. De tal manera se puede seleccionar como la mejor configuración utilizando fase de entrenamiento, validación y prueba: 21-32-24-1, un resultado coherente pues para cada tipo de error la red tuvo los mejores resultados tanto para la fase de entrenamiento como validación.
- Las Redes de Base Radial (RBF) se implementaron con éxito en la detección y clasificación en forma precisa de señales ECG⁶³. La red tiene que cubrir un

⁶² Ocho conjuntos diferentes de características temporales y frecuenciales pertenecientes a las siete arritmias y el ritmo cardiaco normal a reconocer provenientes de MIT-BIH *Arrhythmia Database*, www.physionet.org

⁶³ provenientes de MIT-BIH *Arrhythmia Database*, www.physionet.org

espacio de dimensiones altas, al clasificar ocho conjuntos diferentes de patrones⁶⁴, haciendo uso de la construcción de aproximaciones locales la red logra este objetivo obteniendo excelentes resultados en la fase de entrenamiento como se muestra enseguida: un error cuadrático medio (*mse*) de 2,202E-09, un error absoluto promedio (*mae*) de 4,423E-06 y un error de desviación máxima (*Dmx*) de 4,268E-04; pero pésimos resultados en su fase de validación como se puede ver en los siguientes errores: un error cuadrático medio (*mse*) de 0,643, un error absoluto promedio (*mae*) de 0,2143 y un error de desviación máxima (*Dmx*) de 0,4287.

- Con estos resultados se puede decir que la red de Base Radial logra un alto desempeño clasificando patrones, esto se ve manifestado por los resultados obtenidos al simular la red, los errores en la fase de entrenamiento son aun mucho mejores que los alcanzados anteriormente con la red *Backpropagation* en su mejor configuración, pero con un pobre desempeño en su fase de validación significando que tiene poca capacidad de generalización y se ve superada por la red *Backpropagation* con resultados mas aceptables en su fase de validación.
- La principal ventaja de las redes neuronales es su capacidad para aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante; en términos generales las redes neuronales son una teoría relativamente nueva y como tal presenta aún algunas limitaciones, pero su facilidad de implementación y la calidad en la información que entregan como respuesta, son la motivación suficiente para que su estudio y desarrollo continúe.

⁶⁴ las siete arritmias a reconocer.

Para probar el funcionamiento de la red (tanto la de *Backpropagation* como de *Base Radial*) ante señales nunca antes vistas por el sistema se emplearon señales patrón como seno, cuadrada, triangular y diente de sierra. El sistema arrojó resultados totalmente erróneos (ver Anexo M.) clasificando estas señales patrón dentro de las arritmias cardíacas ya identificadas. Luego se tomaron medidas correctivas incluyendo nuevos patrones para entrenar otra vez la red neuronal (un nuevo reentrenamiento capítulo 2, numeral 2.6), y se pueda hacer una nueva clasificación donde el sistema excluya estas señales patrón de las arritmias cardíacas.

RECOMENDACIONES

Las anotaciones (de los registros electrocardiográficos) del MIT sirven de referencia para comparar los resultados producidos por métodos automáticos de procesamiento, y los producidos según el estándar de los cardiólogos.

Para mejorar el desempeño del sistema de reconocimiento de arritmias presentado en este proyecto se sugiere:

1. Ampliar el número de señales (registros) raramente observadas pero clínicamente significativas para la fase de entrenamiento.
2. Estudio de correlación de los parámetros obtenidos para eliminar redundancias. En este proyecto es el caso del valor RMS (mV) de la señal ECG que está relacionado con el valor de la energía de la señal en el dominio del tiempo.
3. Eliminación de parámetros incapaces de realizar una separación entre clases, obteniendo así un conjunto reducido de parámetros. En este proyecto el parámetro a eliminar es la desviación estándar del espectro calculada a partir de la FFT.
4. Obtención de parámetros adecuados para representación de señales ECG, optimizando resultados ante la discriminación de los diferentes tipos de arritmias. Podría optarse por el estudio de características y prestaciones de las distribuciones tiempo-frecuencia (Transformada *Wavelet*): resolución espectral, propiedades que se cumplen, interpretación de la señal obtenida, etc.

Teniendo un grupo de parámetros adecuado garantiza que la red neuronal pueda llevar a cabo una óptima clasificación y reconocimiento de los diferentes tipos de arritmias. Por último se aconseja, por la alta carga computacional de la red neuronal, un buen procesador para reducir tiempo en la etapa de entrenamiento.

Se sugiere que la E3T tenga su propia base de datos ECG, para que este a disposición de los estudiantes interesados en seguir por esta rama de la bioingeniería.

BIBLIOGRAFÍA

OPPENHEIM, Alan V y WILLSKY. Alan S. Señales y Sistemas. Estados Unidos, Prentice Hall Hispanoamericana S.A., 1994.

Contiene conceptos básicos de tratamiento de señales e importantes en el estudio del dominio del tiempo y la frecuencia, como lo son el análisis de Fourier para señales y sistemas de tiempo continuo y discreto, el teorema del muestreo y características importantes de los filtros.

PROAKIS, John G y MANOLAKIS, Dimitris G. Tratamiento digital de señales. Madrid, Prentice Hall International., 1998.

Presenta un estudio completo y amplio del procesamiento de señales digitales, introduciendo la DFT como herramienta fundamental para la transformación de señales del dominio del tiempo al dominio de la frecuencia. Además, se encuentran otras herramientas importantes (Filtrado y Ventaneo) en el acondicionamiento de las señales para obtener un espectro en frecuencia más confiable.

FAUNDEZ Z., Marcos. Tratamiento Digital de Voz e Imagen. Madrid, Editorial Alfaomega-Marcombo, 2001

Presenta un estudio completo y amplio del tratamiento digital de voz e imagen así como diferentes técnicas de reconocimiento.

WILCHES, Mauricio. Principios Básicos de Fisiología. Tomo II. Colombia, Universidad Antioquia, 1991

Presenta conocimientos esenciales del funcionamiento del corazón y características electrocardiográficas desde el punto de vista de la bioingeniería.

SADAOKI, Furui. *Digital Speech Processing, Síntesis and Recognition.* Japón, Universidad de Tokio. MARCEL DEKKER, INC. 1985.

Presenta un estudio que abarca todo el tratamiento digital de voz, como características, modelos, análisis espectral, y diferentes técnicas de reconocimiento.

HILERA G. José R. y MARTINEZ, H. Víctor J. **Redes Neuronales Artificiales, Fundamentos, Modelos y Aplicaciones.** Madrid, Editorial Addison-Wesley e Iberoamericana, 1995.

Contiene fundamentos básicos de redes neuronales, sus características, sus conexiones, sus diferentes modelos, con sus diferentes aplicaciones en problemas relacionados con el reconocimiento de formas o patrones, predicción, codificación, control y optimización.

ANIL, K. Jain. *Artificial Neural Networks: A Tutorial.* Volumen 29, pp 31-44, IEEE, 1996

Teoría sobre redes neuronales, diferentes dominios, reseña histórica, fundamentos de red neuronal biológica, modelo computacional, arquitecturas y algoritmos de aprendizaje.

NEURAL NETWORK TOOLBOX, for use with MATLAB, Version 3.0, 1998

Contiene toda la ayuda proporcionada por MATLAB 5.3 acerca de redes neuronales, arquitecturas, reglas de aprendizaje, diferentes tipos de entrenamiento, y aplicaciones.

CUESTA FRAU, David. "Estudio de Métodos para Procesamiento y Agrupación de Señales Electrocardiográficas". Tesis Doctoral. Universidad Politécnica de Valencia. Septiembre 2001. Este trabajo presenta un estudio de las técnicas de tratamiento automático de señales cardíacas y el diagnóstico de enfermedades de una forma más eficiente y segura.

<http://plutarco.disca.upv.es/~jcperez/Documentos/TesisDavid.pdf>.

ACEVEDO Antonio y CORINA R. Ailyn. Monitor Virtual del Ritmo Cardíaco. Colombia, Universidad Industrial de Santander, 2000.

Proyecto de grado que permite visualizar en un computador personal un señal electrocardiográfica por medio de una tarjeta de acondicionamiento de señal.

POSADA B. Edwin S. y CASTRO O. Henry. “Analizador de Espectro Virtual”. Colombia, Universidad Industrial de Santander, 2000.

Proyecto de grado que permite adquirir y almacenar señales, por ejemplo de tipo biológicas, para realizar un análisis en el dominio del tiempo y la frecuencia, utilizando un PC compatible IBM y una tarjeta de adquisición de datos.

VILLAMIZAR E. Germán y PÉREZ P. José. Generador de Arritmias Cardíacas Diseño y Construcción. Colombia, Universidad Industrial de Santander, 1999.

Proyecto de grado que impulsa la línea de investigación de la Bioingeniería, en el cual se desarrolla un equipo que emula el ritmo cardíaco normal y las arritmias cardíacas más comúnmente presentes en los pacientes.

OLIVAS, Soria Emilio & SERRANO, López A.J. PROGRAMA DE EMESIS, Redes Neuronales: una breve introducción. En este trabajo se presenta un resumen de la teoría de Redes Neuronales (modelos, arquitecturas, métodos de aprendizaje, ventajas e inconvenientes y aplicaciones).

<http://www.uv.es/~soriae/charla.PDF>

ANDINA De La Fuente, Diego. Tutorial de Redes Neuronales, desarrollado en la Universidad Politécnica de Madrid UPM (España). Contiene una explicación de los distintos tipos de redes según su forma de aprendizaje. <http://www.gc.ssr.upm.es/inves/neural/ann2/anntutor.htm>

MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional - Facultad Regional Rosario, Departamento de Ingeniería Química, Grupo de Investigación Aplicada a la Ingeniería Química. (GIAIQ), Marzo de 2001.

<http://www.modeloingenieria.edu.ar/utnfrro/orientacionl/monografias/matic-h-redesneuronales.pdf>

Presenta teoría muy completa de Redes Neuronales (Reseña histórica, Generalidades, Elementos Básicos, Aprendizaje, validación y codificación, principales topologías, aplicaciones).

GALLEGO, Alfredo Catalina. Introducción a las Redes Neuronales Artificiales. <http://www.gui.uva.es/login/13/redesn.html>.

Contiene teoría detallada acerca de Redes Neuronales; desarrollo histórico; El Perceptrón (estructura, funcionamiento, simulación, aplicaciones).

Alvarado I., Introducción a las redes neuronales artificiales, 1997.

http://www.geocities.com/siliconvalley/campus/9756/Tutorial/RNA_intro.htm

Contiene teoría general de redes neuronales, abarca todo lo que tiene que ver con: modelos de conexiones, estructura y formas de interconexión, funciones de activación y propagación, Redes síncronas y asíncronas, métodos deterministas vs estadísticos.

VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). Facultad Politécnica

– Universidad Nacional de Asunción – Paraguay. Mayo 2000.

<http://www.pol.una.py/tesis/tesis1/index.htm>

Este nodo proporciona una teoría completa de redes neuronales (Reseña histórica, definiciones, ventajas y aplicaciones, conceptos fundamentales, redes neuronales más conocidas, características y ejemplos).

ACOSTA, B. María Isabel, ZULUAGA, M. Camilo A. y SALAZAR, I. Harold, **Tutorial de Redes Neuronales.** Universidad Tecnológica de Pereira, Facultad de Ingeniería Eléctrica. <http://ohm.utp.edu.co/paginas/docencia/neuronales>

En este lugar se encuentra una serie de problemas típicos de Ingeniería Eléctrica, los cuales ya han sido resueltos por métodos tradicionales. Utilizando Redes Neuronales como alternativa novedosa permite solucionar con un enfoque nuevo y eficaz a través de conocimientos matemáticos a un nivel aceptable para comprender el fundamento y desarrollo del problema a resolver.

WELLS, Lisa K. **LabVIEW Student Edition User's Guide.** Estados Unidos, Editorial Prentice Hall, 1994.

Manual básico de LabVIEW, que presenta las librerías con que cuenta el *software* en la implementación de las aplicaciones prácticas en el área de la ingeniería.

National Instruments. LabVIEW Data Acquisition Basics Manual. Estados Unidos, 1998.

Profundiza en el tema de la adquisición de datos, en el conocimiento de las tarjetas de adquisición de datos de la familia *National Instruments* y de las librerías disponibles en LabVIEW para formar un sistema de adquisición óptimo.

PONTILUIS A. Alexander y GONZÁLEZ M. Leonardo E. “**Predicción de los valores máximo y mínimo de la Demanda de Potencia diaria utilizando Redes Neuronales**”. Colombia, Universidad Industrial de Santander, 2000.

Proyecto de grado que permite predecir la demanda diaria, utilizando un PC compatible IBM.

MOMPÍN P., José. “**Introducción a la Bioingeniería**”. Barcelona, España, Marcombo, Boixareu Editores. 1988.

Presenta un análisis desde el punto de vista del campo de la Ingeniería Biomédica.

BORTOLAN Giovanni, DEGANI Rosanna. “Neural Networks for ECG Classification”. University of Leuren, Belgium, IEEE 1991.

Esta publicación presenta la clasificación de ECG implementando una Red Neuronal Artificial con una estructura feed-forward con el algoritmo Backpropagation.

SIED Khursheed Ul Hasnain. “Artificial Neural Networks in Cardiology – ECG wave Analysis and Diagnosis Using Backpropagation Neural Networks”. University of Sciences & Technology, Pakistan Navy Engineering College. IEEE 1999.

En este documento se encuentra la aplicación de una Red Neuronal Artificial en la cardiología.

GANONG, William F. “Fisiología médica”. México, Editorial El Manual Moderno, S.A. de C.V., Decimoquinta edición en español, 1995.

Esta obra proporciona conocimientos de la fisiología del corazón humano y características muy importantes en electrocardiografía.

HERNÁNDEZ Guillermo, MURCIA Adriana Sofía. “Taller de Electrocardiografía Primer nivel”. Fundación Cardiovascular del oriente Colombiano. Tercera Edición. Agosto 2000.

En este taller se ven conceptos básicos en electrocardiografía para ser aplicados en la práctica clínica diaria; se repasan las base teóricas del electrocardiograma, identificación del ritmo sinusal normal, definir e identificar los trastornos de conducción y aclarar dudas sobre los conceptos y patrones electrocardiográficos descritos.

VESGA Boris, CHAVES N. Angel, SANABRIA Claudia Liliana, LINDARTE C. Manuel, RUEDA Oscar Leonel, LEÓN Fidias Eugenio. “Evidencias en Electrocardiografía I: Electrofisiología Cardíaca”. Universidad Industrial de Santander 1999.

Se explica los fenómenos eléctricos que suceden en el músculo cardíaco: la fase de reposo, fase de despolarización, fase de Meseta, fase de repolarización, fase de potencial de Reposo.

VESGA Boris, CHAVES N. Angel, SANABRIA Claudia Liliana, LINDARTE C. Manuel, RUEDA Oscar Leonel, LEÓN Fideas Eugenio. “Evidencias en Electrocardiografía II: Aspectos Básicos para la Toma e Interpretación de un Electrocardiograma” Universidad Industrial Santander 1999.

Se describe el papel utilizado para tomar el electrocardiográfico, calidad de toma de electrocardiograma, ubicación de los electrodos, derivaciones electrocardiográficas, interpretación del electrocardiograma (ritmo, eje eléctrico, ondas componentes P, Q, R, S, T, U; segmentos PR, ST; intervalos PR, QT).

ANEXOS

Anexo A. Historia de las Redes Neuronales

Tabla 56. Historia de las Redes Neuronales

1969	
Alan Turing, fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación.	
	1943
	Warren McCulloch, neurofisiólogo y Walter Pitts, matemático; los primeros teóricos que concibieron los fundamentos de la computación neuronal, lanzaron una teoría acerca de la forma de trabajar de las neuronas, modelando una red neuronal simple mediante circuitos eléctricos.
1949	
Se lanza el libro <i>La organización del comportamiento</i> , de Donald Hebb, donde se tiene una conexión entre psicología y fisiología.	
	1957
	Se inicia el desarrollo del Perceptrón, por Frank Rosenblatt. El Perceptrón es la red neuronal más antigua, y es muy utilizado hasta hoy en día como reconocedor de patrones.
1959	
El modelo ADALINE (ADaptative LINear Elements) es desarrollado por Bernard Widrow y Marcial Hoff. Primera red neuronal aplicada a un problema real, que eran filtros adaptativos para eliminar ecos en las líneas telefónicas, usado durante varias décadas comercialmente.	
	1967
	Stephen Grossberg, de la Universidad de Boston, uno de los mayores investigadores de las redes neuronales desde los años 60 hasta la actualidad realizó una red llamada Avalancha, utilizada para reconocimiento continuo del habla y aprendizaje del movimiento de los brazos de un robot. Además, Grossberg ha escrito muchos libros y desarrollado otros modelos neuronales.

<p>Numerosas críticas frenaron el crecimiento de las investigaciones sobre redes neuronales hasta 1982 debido a un libro publicado por Marvin Minsky y Seymour Papert, del Instituto Tecnológico de Massachusetts (MIT) llamado <i>Perceptrons</i>, el cual contenía un análisis matemático del Perceptrón en forma detallada, y en el que consideraban que la extensión a Perceptrones multinivel era completamente estéril. Hablaban sobre las limitaciones del Perceptrón y su incapacidad para resolver muchos problemas interesantes. Aún así, las investigaciones continuaron. James Anderson desarrolló el modelo lineal llamado Asociador lineal, que consistía en elementos integradores lineales (las neuronas) que sumaban sus entradas. Luego desarrolló una extensión del mismo llamada Brain-State-in-a-Box (BSB). Kuniyiko Fukushima desarrolló el Neocognitrón, modelo de red neuronal para reconocimiento de patrones visuales.</p>	
	<p>1982 Resurge el interés por las redes neuronales a consecuencia de varios eventos. John Hopfield presenta la red que lleva su nombre, que es una variación del Asociador lineal. Se celebró la <i>U.S. – Japan on Cooperative/Competitive Neural Networks.</i></p>
<p>1985 El Instituto Americano de Física comenzó la reunión anual <i>Neural Networks for Computing.</i></p>	
	<p>1987 Se formó la <i>International Neural Network Society (INNS)</i>, con dirección de Grossberg en U.S.A., Kohonen en Finlandia y Amari en Japón.</p>

http://www.pol.una.py/tesis/tesis1/resena_historica.htm

Anexo B. Clasificación de las redes según la información de entrada⁶⁵

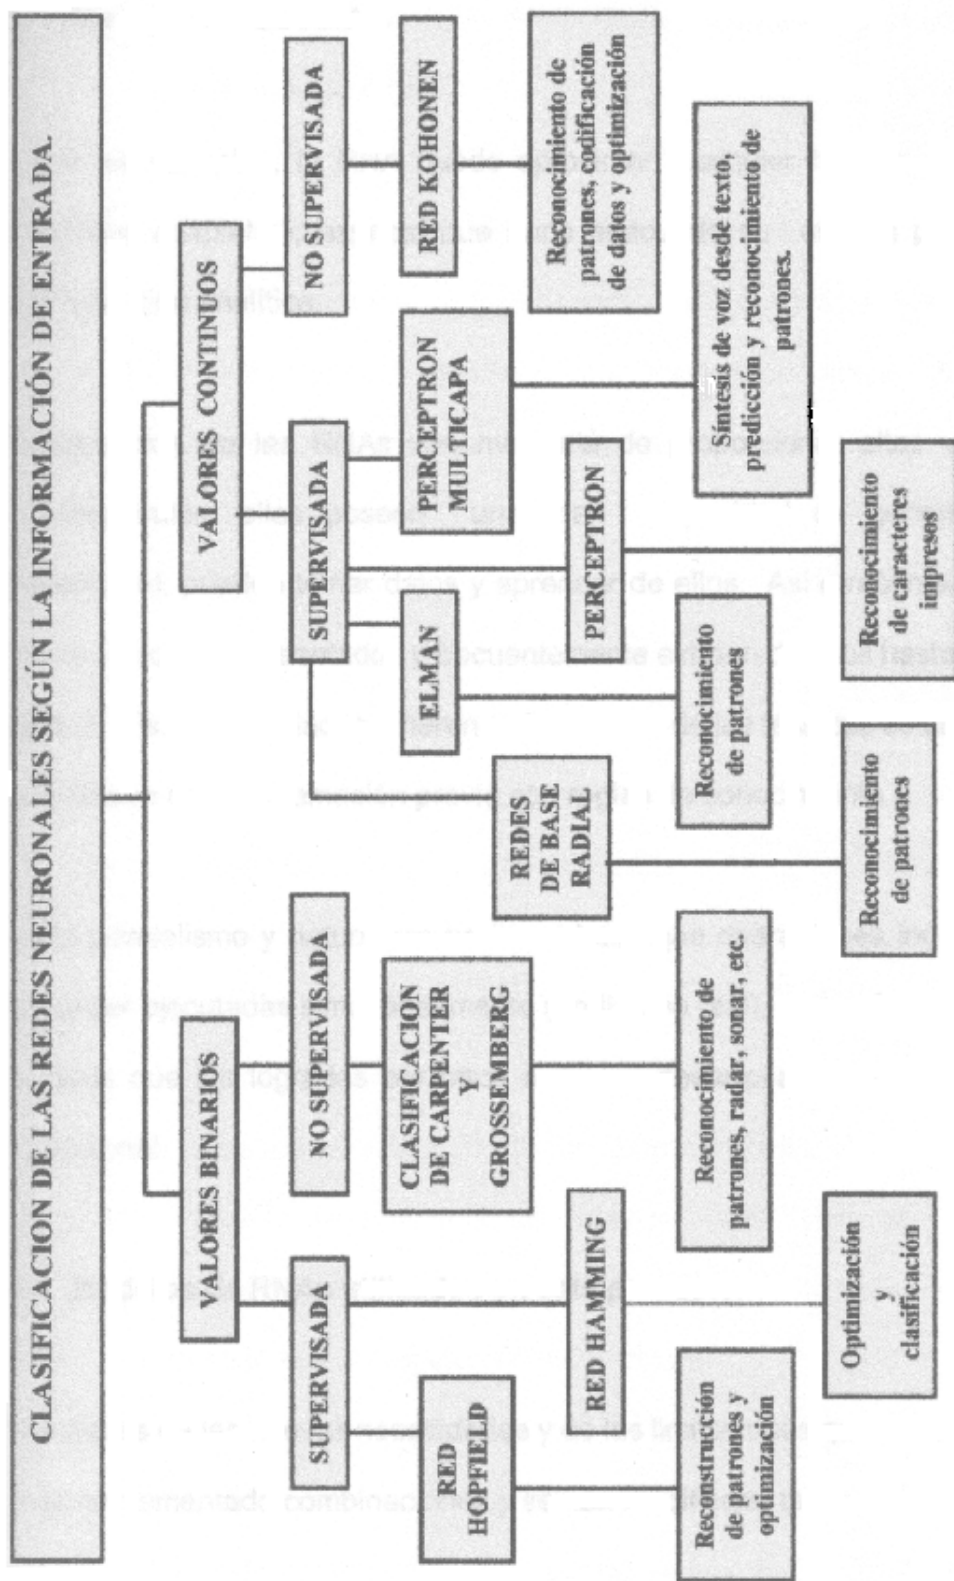


Fig. 56. Clasificación de las redes según la información de entrada

⁶⁵ Pontiluis A. Alexander y Gonzales M. Leonardo M. Predicción de los valores máximo y mínimo de la Demanda de Potencia diaria utilizando Redes Neuronales. Colombia, Universidad Industrial de Santander, 2000. Proyecto de grado.

Anexo C. Redes Neuronales más Conocidas

Tabla 57. Redes Neuronales más Conocidas

Nombre de la red	Año	Aplicaciones más importantes	Comentarios	Limitaciones	Inventada/ desarrollada por
Avalancha	1967	Reconocimiento de habla continua. Control brazos robot.	Ninguna red sencilla puede hacer todo esto.	No es fácil alterar la velocidad o interpolar el movimiento.	Stephen Grossberg.
Teoría Resonancia Adaptativa (ART)	1986	Reconocimiento de patrones (radar, sonar, etc.)	Sofisticada. Poco utilizada.	Sensible a la translación, distorsión y escala.	Gail Carpenter, Stephen Grossberg.
ADALINE / MADALINE	1960	Filtrado de señales. Ecuilizador adaptativo. Modems.	Rápida, fácil de implementar con circuitos analógicos o VLSI.	Sólo es posible clasificar espacios linealmente separados.	Bernard Widrow.
Back Propagation	1974-85	Síntesis de voz desde texto. Control de robots. Predicción. Reconocimiento de patrones.	Red más popular. Numerosas aplicaciones con éxito. Facilidad de aprendizaje. Potente.	Necesita mucho tiempo para el aprendizaje y muchos ejemplos.	Paul Werbos, David Parker, David Rumelhart.
Memoria Asociativa Bidireccional	1985	Memoria heteroasociativa de acceso por contenido.	Aprendizaje y arquitectura simples.	Baja capacidad de almacenamiento. Los datos deben ser codificados.	Bart Kosko.
Máquinas de Boltzmann y Cauchy	1985-86	Reconocimiento de patrones (imágenes, sonar y radar). Optimización.	Redes simples. Capacidad de representación óptima de patrones.	La máquina de Boltzmann necesita un tiempo muy largo de aprendizaje.	Jeffrey Hinton, Terry Sejnowski, Harold Szu.
Brain-Estate -in-a-Box	1977	Extracción de conocimiento de bases de datos.	Posiblemente mejor realización que las redes de Hopfield.	Realización y potenciales aplicados no estudiadas totalmente.	James Anderson
Cerebellatron	1969	Control de movimiento de los brazos de un robot.	Semejante a Avalancha.	Requiere complicadas entradas de control.	David Marr, James Albus, Andres Pellionez.
Counter-propagation	1986	Comprensión de imágenes.	Combinación de Perceptron y TPM	Numerosas neuronas y conexiones.	Robert Hecht-Nielsen.

Hopfield	1982	Reconstrucción de patrones y optimización.	Puede implementarse en VLSI. Fácil de conceptualizar.	Capacidad y estabilidad.	John Hopfield.
Neocognitron	1978-84	Reconocimiento de caracteres manuscritos.	Insensible a la translación, rotación y escala.	Requiere muchos elementos de proceso, niveles y conexiones.	K. Fukushima.
Perceptrón	1957	Reconocimiento de caracteres impresos.	La red más antigua. Construida en HW.	No puede reconocer caracteres complejos.	Frank Rosenblatt.
Self-Organizing-Map (SOM). Topology-Preserving-Map (TPM)	1980-84	Reconocimiento de patrones, codificación de datos, optimización.	Realiza mapas de características comunes de los datos aprendidos.	Requiere mucho entrenamiento.	Teuvo Kohonen.

<http://www.pol.una.py/tesis/tesis1/conocidas.htm>

Anexo D. Algoritmos de aprendizaje más conocidos.

Tabla 58: Algoritmos de aprendizaje más conocidos

Paradigma	Regla de aprendizaje	Arquitectura	Algoritmo de aprendizaje	Tareas
Supervisado	Corrección del error	Perceptrón o perceptrón multicapa	Algoritmos de aprendizaje perceptrón, retropropagación del error, ADALINE, MADALINE	Clasificación de patrones, aproximación de funciones, predicción, control, ...
		Elman y Jordan recurrentes	Retropropagación del error	Síntesis de series temporales
	Boltzmann	Recurrente	Algoritmo de aprendizaje Boltzmann	Clasificación de patrones
	Competitivo	Competitivo	LVQ	Categorización intra-clase, compresión de datos
		Red ART	ARTMap	Clasificación de patrones, categorización intra-clase
No supervisado	Corrección del error	Red de Hopfield	Aprendizaje de memoria asociativa	Memoria Asociativa
		Multicapa sin realimentación	Proyección de Sannon	Análisis de datos
	Competitiva	Competitiva	VQ	Categorización, compresión de datos
		SOM	Kohonen SOM	Categorización, análisis de datos
		Redes ART	ART1, ART2	Categorización
Por Refuerzo	Hebbian	Multicapa sin realimentación	Análisis lineal de discriminante	Análisis de datos, clasificación de patrones
		Sin realimentación o competitiva	Análisis de componentes principales	Análisis de datos, compresión de datos
Híbrido	Corrección de error y competitivo	Redes RBF	Algoritmo de aprendizaje RBF	Clasificación de patrones, aproximación de funciones, predicción, control, ...

Anexo E. Descripción de las Funciones Utilizadas en Matlab

1. Red tipo Perceptrón: Las siguientes son las herramientas de redes neuronales del Matlab 5.3: utilizadas en el entrenamiento de las redes neuronales correspondientes a las aplicaciones del proceso de detección de obstáculos de un robot y Control de cambio de giro de un motor trifásico.

- ***newp***: Crea una red tipo Perceptrón, que requiere las siguientes entradas:

$NET = NEWP(PR,S,TF,LF)$

PR : Rx2 matriz de valores máximos y mínimos para los R elementos de entrada.

S : Número de neuronas.

TF : Función de Transferencia, en este caso 'hardlims'.

LF : Función de aprendizaje, para este caso 'learnp'.

- ***rands***: Función simétrica que inicializa aleatoriamente los valores de pesos y ganancias de una red con valores entre -1 y 1; requiere de la estructura

$rands(S,PR)$, generando una matriz de dimensiones S x PR.

- ***adapt***: Permite a una red neuronal adaptarse a los patrones de entrada, esta función tiene la siguiente sintaxis:

$[net,Y,E,Pf,Af] = adapt(NET,P,T,Pi,Ai)$

net : Red que va a crearse

P : Entradas a la red; deben aparecer en forma de un arreglo de matrices.

T : Salidas esperadas de la red, si no se especifican son ceros por defecto.

Pi : Condiciones de retardo para la entrada inicial, por defecto son

ceros.

A_i : Condiciones de retardo para la capa inicial, por defecto ceros

- ***net.adaptParam.passes***: Número de iteraciones que utiliza el programa.

2. Red tipo Adaline: Las siguientes son las funciones de las herramientas de Redes Neuronales del Matlab utilizadas en el entrenamiento del filtro adaptivo diseñado con base en una red Adaline.

- ***newlin***: Función para crea una red tipo Adaline, que requiere las siguientes entradas:

NEWLIN(PR,S,ID,LR)

R: Matriz de Rx2 que contiene los valores máximos y mínimos de cada uno de los R elementos de entrada.

S : Número de neuronas

ID : Arreglo que contiene los valores de los retardos, por defecto todos sus valores son cero.

LR : Rata de aprendizaje, por defecto = 0.01

- ***net.inputWeights{1,1}.delays***: Especifica los retardos iniciales
- ***net.adaptParam.passes***: Número máximo de iteraciones
- ***[net,y,E,pf,af]=adapt(net,p,T,pi)***: Comando de entrenamiento de la red; requiere como entradas la red creada anteriormente, los patrones de entrada, las salidas esperadas y los retardos iniciales, retorna el estado final de la red, los valores obtenidos para cada patrón de entrada con sus correspondientes errores así como los valores finales de los retardos.

3. Red tipo Backpropagation: La red neuronal Backpropagation presenta una gran variedad de opciones de configuración, dependiendo de la necesidad de aprendizaje y de la aplicación que se este desarrollando.

- **newff:** Crea una red tipo Backpropagation, requiere que le sean especificados los siguientes parámetros

newff: (PR,[S1 S2...SNI},{TF1 TF2...TFNI},BTF,BLF,PF)

PR : Rx2 Matriz de valores máximos y mínimos de cada uno de las R neuronas de entrada.

Si : Número de neuronas para cada una de las capas.

TFi : Función de transferencia a utilizar en cada una de las capas, por defecto utiliza *tansig*

BTF : Algoritmo de entrenamiento a utilizar, por defecto utiliza *trainlm*

BLF : Función de actualización de los pesos, por defecto utiliza *learnqdm*.

PF : Función para evaluar el desempeño de la red, por defecto utiliza *mse*.

3.1 Traingd: Algoritmo de pasos descendientes, que actualiza pesos y ganancias variándolos en la dirección negativa del gradiente de la función del error. Es un algoritmo de aprendizaje muy lento, que requiere de la siguiente sintaxis:

- *net.trainParam.epochs:* Máximo número de iteraciones para obtener convergencia
- *net.trainParam.goal:* Error máximo permitido
- *net.trainParam.lr:* Rata de aprendizaje
- *net.trainParam.max_fail:* Máximo número de fallas
- *net.trainParam.min_grad:* Mínimo rendimiento del gradiente
- *net.trainParam.show:* Intervalo de visualización de los resultados
- *net.trainParam.time:* Máximo tiempo de entrenamiento en segundos

Con este algoritmo el aprendizaje de la red se detendrá si el número de iteraciones excede el comando *net.trainParam.epochs*, si se alcanzó el valor del error propuesto como meta, si la magnitud del gradiente es menor que *net.trainParam.min_grad*, o si el tiempo de entrenamiento supera el valor de *net.trainParam.time*.

3.2 Traingdm: Equivale al algoritmo tradicional, más un nuevo coeficiente de momentum, que interviene en el proceso de actualización de los pesos. Si el error de la red en una iteración dada, excede el valor del error en la iteración anterior, en un valor mayor al definido por un radio de cobertura dado el que puede determinarse por medio de la función *max_perf_inc* y que está típicamente alrededor de 1.04, los nuevos pesos y ganancias son descartados y el coeficiente de momentum *mc* es fijado en cero.

La sintaxis de este algoritmo es igual a la utilizada para el algoritmo *traingd*, más un nuevo comando que permite modificar el coeficiente de momentum

- *net.trainParam.mc*: Valor fijado para el coeficiente de momentum

3.2 Traingda: Algoritmo de Gradiente Descendiente, que emplea una tasa de aprendizaje adaptiva durante el proceso de entrenamiento. La tasa de aprendizaje varía entre 0.01 y 1, una tasa de aprendizaje muy pequeña torna lento el aprendizaje, pero si se incrementa demasiado el aprendizaje puede tornarse inestable y crear divergencia, por esto la función *traingda* varía la tasa de aprendizaje tratando de sacar provecho de la inclinación del gradiente en cada momento; su gran desventaja es que los pesos iniciales varían muy poco así se encuentren distantes de los valores de convergencia. La sintaxis de este el algoritmo es la siguiente:

- *net.trainParam.epochs*: Máximo número de iteraciones para obtener convergencia
- *net.trainParam.goal*: Error máximo permitido
- *net.trainParam.lr*: Tasa de aprendizaje inicial

- *net.trainParam.lr_inc*: Porcentaje que incrementa la tasa de aprendizaje cuando el error disminuye
- *net.trainParam.lr_dec*: Porcentaje en que es decrementada la tasa de aprendizaje cuando el error aumenta
- *net.trainParam.max_fail*: Máximo número de fallas
- *net.trainParam.max_perf_inc*: Máximo incremento del rendimiento
- *net.trainParam.min_grad*: Mínimo rendimiento del gradiente
- *net.trainParam.show*: Los resultados son visualizados siempre que transcurre este número de iteraciones.
- *net.trainParam.time*: Máximo tiempo de entrenamiento en segundos

3.3 Trainrp: Las redes multicapa, utilizan típicamente una función de transferencia sigmoideal (ver capítulo 1) en las capas ocultas, estas funciones comprimen un infinito rango de entradas, dentro de un finito rango de salidas, además se caracterizan porque su pendiente tendera cada vez más a cero, mientras más grande sea la entrada que se le presenta a la red, esto ocasiona problemas cuando se usa un algoritmo de entrenamiento de pasos descendientes, porque el gradiente empieza a tomar valores muy pequeños y por lo tanto no habrán cambios representativos en los pesos y las ganancias, así se encuentren bastante lejos de sus valores óptimos. El propósito del algoritmo Backpropagation Resilient (RPROP) es eliminar este efecto en la magnitud de las derivadas parciales. En este algoritmo solamente el signo de la derivada es utilizado para determinar la dirección de actualización de los parámetros, la magnitud de las derivadas no tiene efecto en la actualización. La magnitud en el cambio de cada peso es determinada por separado; el valor del incremento de pesos y ganancias es determinado por el factor *delt_inc*, así la derivada parcial del error con respecto a los pesos tenga el mismo signo durante dos iteraciones sucesivas; el valor de decremento está determinado por el factor *delt_dec* así la derivada del error con respecto a los pesos haya cambiado de signo con respecto a la anterior iteración; si la derivada es cero, entonces el valor actualizado se conserva; si los pesos continúan cambiando

en la misma dirección durante varias iteraciones, la magnitud de cambios de los pesos se decrementa.

La sintaxis de este algoritmo se resume a continuación:

- *net.trainParam.epochs*: Máximo número de iteraciones del entrenamiento
- *net.trainParam.show*: Intervalo de visualización de los resultados
- *net.trainParam.goal*: Error deseado
- *net.trainParam.time=inf*: Máximo tiempo de entrenamiento en segundos
- *net.trainParam.min_grad*: Mínimo rendimiento del gradiente
- *net.trainParam.max_fail*: Máximo número de fallas
- *net.trainParam.lr*: Rata de aprendizaje
- *net.trainParam.delt_inc*: Incremento en la actualización de pesos
- *net.trainParam.delt_dec*: Decremento en la actualización de pesos
- *net.trainParam.delta0*: Incremento inicial en la actualización de pesos
- *net.trainParam.deltamax*: Máximo cambio en los pesos

3.4 Trainbfg: Algoritmo alternativo que emplea la técnica del gradiente conjugado, su expresión matemática se deriva del método de Newton, con la ventaja de que no es necesario computar las segundas derivadas; este algoritmo requiere más capacidad de almacenamiento que el algoritmo tradicional, pero generalmente converge en menos iteraciones. Requiere de un cálculo aproximado de la matriz Hessiana, la cual es de dimensiones $n^2 \times n^2$, donde n la cantidad de pesos y ganancias de la red; para redes que involucren una gran cantidad de parámetros es preferible emplear el algoritmo *trainrp*.

- *net.trainParam.epochs*: Máximo número de iteraciones del entrenamiento
- *net.trainParam.show*: Número de iteraciones entre las cuales se muestran resultados
- *net.trainParam.goal*: Error deseado
- *net.trainParam.time=inf*: Máximo tiempo de entrenamiento en segundos
- *net.trainParam.min_grad*: Mínimo rendimiento del gradiente

- `net.trainParam.max_fail=5`: Máximo número de fallas
- `net.trainParam.searchFcn 'srchcha'`: Nombre de la rutina de búsqueda lineal a utilizar.
- `net.trainParam.scal_tol`: Se divide entre el valor de Delta para determinar la tolerancia para la búsqueda lineal.
- `net.trainParam.alpha`: Factor de escala que determina una reducción suficiente en el desempeño.
- `net.trainParam.beta`: Factor de escala que determina un tamaño de paso suficientemente grande.
- `net.trainParam.delta`: Tamaño de paso inicial en el intervalo de localización de paso.
- `net.trainParam.gama`: Parámetro para evitar pequeñas reducciones en el desempeño.
- `net.trainParam.low_lim`: Límite inferior en el cambio del tamaño del paso.
- `net.trainParam.up_lim`: Límite superior en el cambio del tamaño del paso.
- `net.trainParam.maxstep`: Máximo longitud de paso.
- `net.trainParam.minstep`: Mínima longitud de paso; por defecto es 1.0e-6
- `net.trainParam.bmax`: Máximo tamaño de paso.

3.5 Trainlm: Algoritmo que actualiza los pesos y las ganancias de acuerdo a la optimización de Levenberg-Marquardt. Es el algoritmo más rápido para redes Backpropagation; tiene la desventaja de requerir de un set de entrenamiento lo más estándar posible, pues de otra forma solo aproximará correctamente valores que se encuentren dentro de los patrones de aprendizaje. Si el set de entrenamiento es muy extenso, se recomienda reducir el Jacobiano.

La sintaxis de este algoritmo es la siguiente:

- `net.trainParam.epochs`: Máximo número de iteraciones del entrenamiento
- `net.trainParam.goal`: Error deseado
- `net.trainParam.lr`: Rata de aprendizaje

- *net.trainParam.max_fail*: Máximo número de veces que falla el valor de Mu
- *net.trainParam.mem_reduc*: Factor de fraccionamiento de Jacobiano para ahorrar memoria
- *net.trainParam.min_grad*: Mínimo rendimiento del gradiente
- *net.trainParam.show*: Intervalo de visualización de los resultados.
- *net.trainParam.time*: Máximo tiempo de entrenamiento en segundos
- *tr.mu*: Valor del Mu adaptivo


Anexo F. Valores de cortes de frecuencia del tipo de filtro escogido

- **Frecuencia de corte bajo:** Es el único control usado cuando se usan filtros pasa-bajos y pasa-altos.
- **Frecuencia de corte alto:** No es usada cuando el tipo de filtro es pasa-bajos y pasa-altos. Debe ser mayor que la frecuencia de corte baja del filtro y menor que la mitad de la frecuencia de muestreo.
- **Frecuencia de rechazo bajo:** Es usada, junto con la frecuencia de rechazo alta, cuando el tipo de filtro es banda de paso o banda de rechazo.
- **Frecuencia de rechazo alto:** Es usada, junto con la frecuencia de rechazo baja, cuando el tipo de filtro es banda de paso o banda de rechazo.

Otros valores de entrada importantes son:

- **Rizado (ripple):** Este valor controla el rizado de la banda de paso. Este valor se puede modificar únicamente desde el diagrama de bloques del subvi de filtros, ya que no es una entrada común para todos.
- **Orden del filtro:** entrada que permite, al aumentarlo, obtener caídas más abruptas en las transiciones del filtro.

Anexo G. Ondas, Segmentos y Complejos Electrocardiográficos



- **SEGMENTO:** Es la línea isoelectrónica que va desde el final de una onda hasta el comienzo de la siguiente.
- **INTERVALO:** Comprende un segmento y la onda inmediatamente anterior y/o posterior a éste.
- **INTERVALO PR o PQ:** Incluye la onda P y el segmento PQ; va desde el comienzo de la onda P hasta el comienzo del complejo QRS.
- **COMPLEJO QRS:** Producido por la despolarización ventricular. Lo constituyen las ondas Q, R, S; no siempre están presentes Q y S. Toda onda negativa que inicie el complejo o preceda a R, se denomina onda Q. La onda positiva del

complejo se denomina R; toda onda negativa que ésta después de R, dentro del complejo, se denomina S; si todo el complejo es negativo se llama QS.

- **SEGMENTO ST:** Va desde el final de la onda S, hasta el comienzo de la onda T. Generalmente es isoeléctrico.

El sitio de unión entre el complejo QRS y el segmento ST se denomina punto J.

- **ONDA T:** Representa la repolarización ventricular. Normalmente es asimétrica, con pendiente de ascenso menor que la de descenso y a veces está seguida por una pequeña onda denominada onda U.
- **INTERVALO R-R:** Va desde el punto máximo de una onda R hasta el punto máximo de la onda R siguiente; su duración varía con la frecuencia cardiaca.
- **ONDAS P y T:** Usualmente muestran una morfología similar en todas las derivaciones.

Anexo H. Derivaciones

Dependiendo de la posición sobre la superficie del cuerpo del paciente donde se coloquen los electrodos, se tendrán distintas derivaciones o pares de puntos. En resumen, estas derivaciones son:

- **Bipolares**. Las que se obtienen con el llamado triángulo de *Einthoven* (Figura 86). Los electrodos se colocan en las extremidades.
- **Aumentadas**. Variantes de las anteriores.
- **Unipolares**. Obtenidas con los electrodos situados sobre el tórax del paciente.

Existen otras menos conocidas, pero a veces importantes, que son variantes de las unipolares: V7,V8,V9, que enfrentan la parte posterior del corazón, y RV1, RV2, que enfrentan el ventrículo derecho.




Figura 57. Triángulo de Einthoven.

Las tablas 60 y 61 muestran las principales derivaciones, con la posición de los electrodos, la nomenclatura utilizada, y la polaridad de las ondas, respectivamente.

Tabla 59. Descripción de las principales derivaciones.

Derivación	Posición electrodos	Nomenclatura
Bipolar	RL,LL,RA,LA	I=LA-RA II=LL-RA III=LL-LA
Aumentadas	RL,LL,RA,LA	aVR=RA-0.5(LA+LL) aVL=LA-0.5(LL+RA) aVF=LL-0.5(LA+RA)
Unipolares	v1,v2,v3,v4,v5,v6	$V_1 = v_1 - \frac{(LA + RA + LL)}{3}$ $V_2 = v_2 - \frac{(LA + RA + LL)}{3}$ $V_3 = v_3 - \frac{(LA + RA + LL)}{3}$ $V_4 = v_4 - \frac{(LA + RA + LL)}{3}$ $V_5 = v_5 - \frac{(LA + RA + LL)}{3}$ $V_6 = v_6 - \frac{(LA + RA + LL)}{3}$
Ortogonales	I,E,C,A,M,H,F	X=0.610 A+0.171 C-0.781 I Y=0.655 F+ 0.345 M- 1.000 H Z=0.133 A+ 0.736 M - 0.264 I - 0.374 E - 0.231 C

Tabla 60. Derivaciones electrocardiográficas y polaridad de las ondas.

Derivación	Onda P	Complejo QRS	Onda T
I	+	+	+
II	+	+	+
III	+/-	+/-	+/-
VR	-	-	-
aVL	+/-	+/-	+
aVF	+	+	+
V1	+/-	-	-
V2	+/-	+/-	+/-
V3	+	+	+
V4	+	+	+
V5	+	+	+
V6	+	+	+

Anexo I. Patologías

En este apartado se describen algunas de las patologías más comunes así como sus manifestaciones en el ECG.

- *Agrandamiento auricular.* En el ECG de un corazón con funcionamiento normal, las ondas P son pequeñas. Si existe sobrecarga o hipertrofia de la aurícula derecha, esta onda se hace mayor pero permanece estrecha. Por el contrario, si la aurícula izquierda está agrandada, la onda P se ensancha.
- *Hipertrofia ventricular.* Se incrementa la masa muscular debido a un incremento de carga u otros motivos. Las consecuencias en el ECG son el aumento del complejo QRS en amplitud y duración.
- *Defectos de conducción ventricular.* Consiste en una anormal iniciación de la activación de los ventrículos. Se manifiesta en una mayor duración del complejo QRS.
- *Preexcitación.* Se da cuando la conducción del impulso eléctrico de la aurícula al ventrículo se realiza por canales distintos a la unión auriculo-ventricular. Se manifiesta en un anormal patrón del complejo QRS.
- *Infarto.* Cuando el músculo cardiaco se queda sin suficiente aporte sanguíneo (isquemia), el potencial transmembrana de las células dañadas se hace menor, resultando un segmento ST elevado en la región dañada. Conforme van muriendo las células, se va perdiendo la onda R y se forman ondas Q. El cambio final es la inversión y ensanchamiento de las ondas T.
- *Patologías asociadas con el entorno cardiaco.* Son alteraciones en el ECG debido no al corazón, sino al volumen conductor que lo rodea, como el caso de la pericarditis. En este caso la superficie externa del corazón se inflama. Se produce una elevación en el segmento ST.

- *Taquicardia*. Corresponde a un ritmo cardiaco anormalmente alto. Puede ser supraventricular o auricular, y ventricular. Su aparición es debida a la formación de un circuito que permite el inicio de un ciclo continuo automantenido. La taquicardia por “reentrada” sí es debida a la formación de este circuito automantenido, pero existe otro posible mecanismo, la taquicardia por “automatismo”, en el que existe un foco de células que se despolarizan automáticamente por su cuenta, transmitiendo el impulso al resto. En la figura 2.5 se muestra un ejemplo de arritmia.
- *Fibrilación*. Corresponde a un ritmo caótico, asociado con un funcionamiento no útil de las cámaras asociadas. Puede darse en la aurícula o en el ventrículo, siendo este último la causa de muerte en pacientes cardíacos.
- *Bloqueo AV*. Cuando el tejido no transmite el impulso de aurícula a ventrículo, el corazón puede parar completamente. Se debe sospechar cuando el músculo ventricular responde con un ritmo muy bajo, de unos 30lpm o incluso menor. Estos latidos son de “escape”, pues al no llegarle impulso, el ventrículo termina por despolarizarse automáticamente, aunque sólo puede hacerlo muy lentamente.

Anexo J. Instrumento Virtual

Antecedentes

El concepto de *instrumentación virtual* nace a partir del uso de la PC como instrumento de medición de variables físicas (temperatura, presión, caudal), representadas por señales analógicas de corriente o voltaje eléctricos. Este concepto va más allá de la simple medición de corriente o voltaje, pues también involucra el procesamiento, análisis, almacenamiento, distribución y despliegue de los datos e información relacionados con la medición de una o varias señales específicas. El instrumento virtual utilizado para la adquisición de la señal, comprende también la interfaz hombre-máquina, las funciones de análisis y procesamiento de señales, las rutinas de almacenamiento de datos y la comunicación con otros equipos.

El término *virtual* surge de la funcionalidad y apariencia que –por software– el usuario puede definir para la PC utilizada como instrumento, creando una flexibilidad que no depende del fabricante como en el caso de los instrumentos tradicionales.

El *instrumento virtual* queda definido entonces como el conjunto de software y hardware que agregado a una PC permite a los usuarios interactuar con la computadora como si se estuviera utilizando un instrumento electrónico hecho a medida (Alvarado, 1997).

El software es la esencia del sistema de instrumentación virtual –como el hardware lo es para un instrumento tradicional–, ya que es el que le confiere la *flexibilidad* necesaria para variadas aplicaciones y modos de operación (termómetros, control de funcionamiento de motores, análisis de señales biomédicas), seleccionables por programa. El instrumento virtual se completa con una tarjeta apropiada para la captura, conversión y acondicionamiento de las señales eléctricas representativas de las variables físicas a estudiar.

El objetivo del presente trabajo es mostrar las facilidades proporcionadas por una herramienta de instrumentación virtual para el procesamiento y análisis de señales electrocardiográficas.

Software. Para la configuración del instrumento virtual se utilizó el programa LabVIEW (**L**aboratory **V**irtual **I**nstrument **E**ngineering **W**orkbench), uno de los más difundidos para aplicaciones de instrumentación virtual, y que está basado en el lenguaje gráfico de programación G para facilitar la interacción sistema-usuario, y orientado particularmente a la adquisición de datos (Wells, 1995a; Wells, 1995b). Este software puede reemplazar la utilización de programas específicos de adquisición de datos, usualmente provistos con la tarjeta de conversión A/D (National Instruments, 1996b).

La particularidad del lenguaje G consiste en la posibilidad de programar gráficamente a partir de la asociación de objetos denominados módulos VI (i.e. *virtual instrument*), reduciendo considerablemente los tiempos de desarrollo para lograr la adquisición, control, análisis y presentación de datos.

Configuración de un Instrumento Virtual

En la configuración de un instrumento virtual se distinguen tres partes, como se ilustra en la Figura 1 (Wells, 1995a; Wells, 1995b):

a) *Panel frontal* o interfaz interactiva de usuario, que simula el panel de un instrumento físico. El panel frontal puede tener perillas, botones de comando, y otros controles que son las entradas del usuario. También se pueden simular indicadores que constituyen la salida del programa. Los datos se pueden ingresar por mouse o teclado, visualizándose en pantalla los resultados del programa o proceso (Fig. 1 (a)).

b) *Código gráfico* o diagrama en bloques. El diagrama es el código fuente del instrumento virtual, y se construye utilizando el lenguaje G de programación gráfica. Es este lenguaje de programación el que permite que una

representación pictórica de los bloques del instrumento sea en realidad el programa que va a ejecutarse (Fig. 1(b)).

c) *Íconos y conectores* son los componentes del código gráfico. Los íconos representan módulos VI, funciones o estructuras de control de programa. Los conectores indican el flujo de entrada y salida de los datos en el diagrama en bloques. La naturaleza jerárquica y modular de los íconos posibilita su utilización como sub-módulos VI, permitiendo la elaboración de sub-rutinas y la programación modular (Fig. 1(b)).

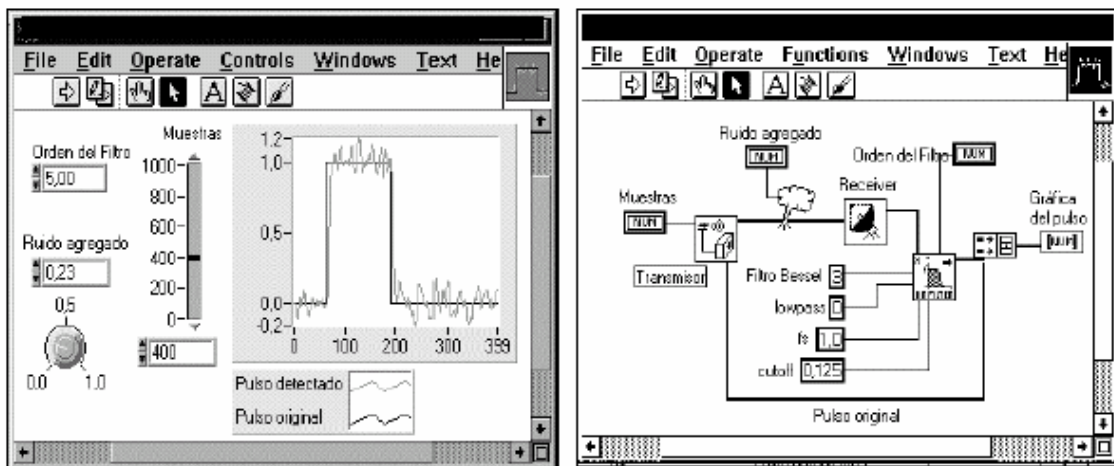


Figura 58. Ejemplo de un instrumento virtual. (a) Panel frontal con controles e indicadores. (b) Código gráfico con íconos y conectores (Wells, 1995a)

Anexo K. Redes Neuronales Artificiales

1.1 Redes Neuronales

1.1.1 La neurona biológica

Una neurona biológica es una célula especializada en procesar información. Está compuesta por el cuerpo de la célula (soma) y dos tipos de ramificaciones: el axón y las dendritas (figura 1). La neurona recibe señales (impulsos) de otras neuronas a través de sus dendritas y transmite señales generadas por el cuerpo de la célula a través del axón.

El córtex cerebral humano contiene alrededor de 10^{11} neuronas (aproximadamente el mismo número de estrellas que hay en la Vía Láctea). Cada neurona está conectada de forma masiva a un número variable de entre 1000 y 10.000 neuronas. Por tanto, el cerebro contiene de 10^{14} a 10^{15} interconexiones.




Figura 59. Neurona biológica

Las neuronas se comunican entre sí mediante trenes de pulsos de corta duración (del orden de milisegundos). El mensaje, está modulado en la frecuencia de transmisión de los pulsos. Esta frecuencia varía sobre los 100 hz. Por tanto, es más de un millón de veces inferior a la velocidad de conmutación de los circuitos electrónicos típicos de nuestros días.

Sin embargo, el ser humano es capaz de realizar tareas complejas en un tiempo inferior y con un porcentaje de aciertos superior al conseguido actualmente mediante ordenadores. Por ejemplo, tareas de reconocimiento del habla, locutor a través de su voz, cara, etc. Ello es debido a la paralelización masiva que realiza el cerebro, que está extremadamente lejos de poder ser implementada en un circuito electrónico.⁶⁶

1.1.2 Definiciones de lo que son Redes Neuronales Artificiales

Abajo se citan algunas de las numerosas definiciones de lo que son RNA:

- En definitiva, las redes neuronales no son más que un modelo artificial y simplificado del cerebro humano, que es el ejemplo más perfecto del que disponemos para un sistema que es capaz de adquirir conocimiento a través de la experiencia. Una red neuronal es “un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: *la neurona*”.⁶⁷

⁶⁶ Tratamiento digital de voz e imagen. Marcos Faúndez Zanuy. Alfaomega-Marcombo 2001

⁶⁷ MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones.
<http://www.modeloingenieria.edu.ar/utnfrro/orientacionl/monografias/matich-redesneuronales.pdf>

- Como definición general se puede hablar de *red neuronal artificial* como todo aquel dispositivo que se diseña para modelizar el comportamiento del cerebro ante una determinada tarea.⁶⁸
- “Redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico.”⁶⁹
- “... un sistema de computación hecho 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.”
- “Lo que actualmente se conoce como redes de neuronas artificiales corresponde a un modo de computación analógica no lineal, distribuida, organizada por capas y autoprogramable que utiliza como computación local un modelo muy primitivo de neurona biológica.” *
- “Se entiende por computación neuronal al cálculo realizado por arquitecturas modulares con un gran número de elementos de cálculo con un alto grado de conectividad y realizando localmente una función analógica no lineal (suma ponderada seguida de una función de decisión tipo umbral o sigmoide).” *
- “Las redes de neuronas son dispositivos diseñados a imitación de los sistemas nerviosos de los animales. Consisten en una interconexión

⁶⁸ OLIVAS, Soria Emilio & SERRANO, López A.J. PROGRAMA DE EMESIS, Redes Neuronales: una breve introducción. <http://www.uv.es/~soriae/charla.PDF>

⁶⁹ * VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/definiciones.htm>

reticular de unidades, frecuentemente llamadas neuronas artificiales, o simplemente neuronas, cuyo funcionamiento se inspira en el de las neuronas naturales.”

1.1.3 Reseña histórica

- Los primeros estudios fueron realizados por McCulloch y Pitts en 1949. Mostraron la habilidad de un grupo de neuronas conectadas para llevar a cabo la implementación de ciertas funciones lógicas.⁷⁰

- Durante la década de los 50 hubo un considerable crecimiento en este campo.

Rosenblatt en 1958 introdujo la primera arquitectura de red de neuronas artificial con capacidad de aprendizaje: **El perceptrón simple**.*

- En 1969 y debido a que se demostraron las serias limitaciones de dicha red, la mayor parte de los investigadores en este área abandonaron su trabajo.*
- A principios de la década de los 80, las redes de neuronas artificiales volvieron a renacer.

En 1986, Rumelhart, Mc Clland and Willians propusieron el **perceptrón multicapa** y el algoritmo de retropropagación.*

En el anexo A, se representa en forma general los acontecimientos más importantes en la historia de las Redes Neuronales.

^{70*} Tutorial con teoría detallada:

<http://www.paisvirtual.com/informatica/navegadores/toniomos/rn/temas-rn.htm>

1.2 Modelo de neurona artificial

Las redes neuronales artificiales pretenden emular la red neuronal biológica y se obtienen interconectando neuronas. Para ello se supone un modelo matemático simplificado de la neurona biológica.

Este modelo es una generalización del propuesto por McCulloch y Pitts en 1943:

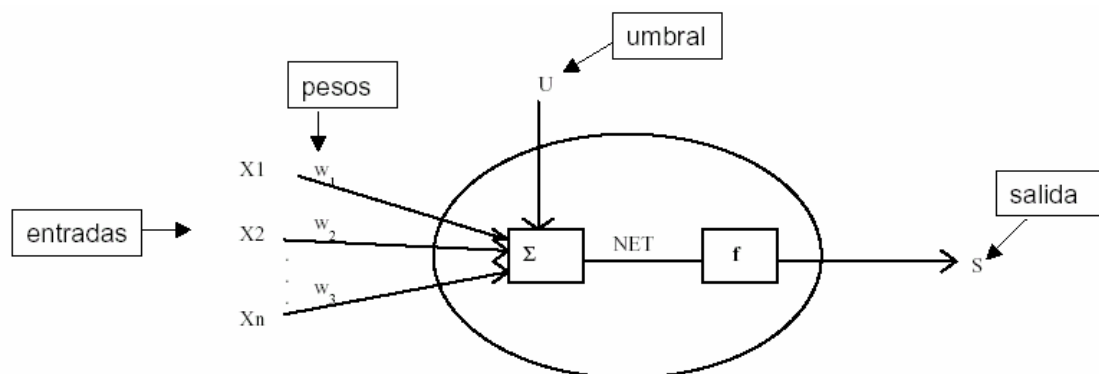


Figura 60. Modelo de neurona artificial

La salida de la neurona es:

$$S = f(NET) \quad (1)$$

f es la función de activación

$$NET = X_1 * w_1 + X_2 * w_2 + \dots + X_n * w_n + U = \sum_{i=1}^n X_i * w_i + U \quad (2)$$

La neurona recibe del exterior un umbral U o b y N entradas a las que asocia un conjunto de pesos \$w_i\$ (\$i=1, \dots, N\$). Aplicando el producto de los pesos por las entradas respectivas más el umbral (o desplazamiento) a una función de activación \$f(u)\$, se obtiene la salida "y" ec. (1).

Como se muestra en la figura, la neurona se activa si la fuerza combinada de la señal de entrada es superior a un cierto nivel, en el caso general el valor de

activación de la neurona viene dado por una función de activación $f(\cdot)$. La figura 3. muestra las funciones de activación más comunes.

1.3 Elementos básicos que componen una red neuronal.

A continuación se puede ver, en la *Figura 3.*, un esquema de una red neuronal:




Figura 61. Ejemplo de una red neuronal totalmente conectada.

La misma está constituida por neuronas interconectadas y arregladas en tres capas (esto último puede variar). Los datos ingresan por medio de la “*capa de entrada*”, pasan a través de la “*capa oculta*” y salen por la “*capa de salida*”. Cabe mencionar que la capa oculta puede estar constituida por varias capas.⁷¹

1.3.1 Función de entrada (*input function*).

La neurona trata a muchos valores de entrada como si fueran uno solo; esto recibe el nombre de *entrada global*. Por lo tanto, ahora nos enfrentamos al

⁷¹ * MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones. <http://www.modeloingenieria.edu.ar/utnfrro/orientacion/monografias/matich-redesneuronales.pdf>

problema de cómo se pueden combinar estas simples entradas (p_1, p_2, \dots, p_n) dentro de la entrada global. Esto se logra a través de la *función de entrada*, la cual se calcula a partir del *vector entrada*. La función de entrada puede describirse como sigue:^{*}

$$input = (p_{i1} \bullet w_{i1}) * (p_{i2} \bullet w_{i2}) * \dots * (p_{in} \bullet w_{in}) \quad (3)$$

donde: * representa al operador apropiado (por ejemplo: máximo, sumatoria, productoria, etc.), n al número de entradas a la neurona p_i y w_i al peso.

Los valores de entrada se multiplican por los pesos anteriormente ingresados a la neurona. Por consiguiente, los pesos que generalmente no están restringidos cambian la medida de influencia que tienen los valores de entrada. Es decir, que permiten que un gran valor de entrada tenga solamente una pequeña influencia, si estos son lo suficientemente pequeños.⁷²

Algunas de las funciones de entrada más comúnmente utilizadas y conocidas son:

1. **Sumatoria de las entradas pesadas:** es la suma de todos los valores de entrada a la neurona, multiplicados por sus correspondientes pesos.^{*}

$$\sum_j (p_{ij} w_{ij}), \text{ con } j = 1, 2, \dots, n \quad (4)$$

2. **Productoria de las entradas pesadas:** es el producto de todos los valores de entrada a la neurona, multiplicados por sus correspondientes pesos.^{*}

⁷² * MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones.
<http://www.modeladoingenieria.edu.ar/utnfrro/orientacionl/monografias/matich-redesneuronales.pdf>

$$\prod_j (p_{ij} w_{ij}), \text{ con } j = 1, 2, \dots, n \quad (5)$$

3. **Máximo de las entradas pesadas:** solamente toma en consideración el valor de entrada más fuerte, previamente multiplicado por su peso correspondiente.*

$$\text{Max}_j (p_{ij} w_{ij}), \text{ con } j = 1, 2, \dots, n \quad (6)$$

4. **Base Radial (RBF) :** es una función de tipo hiperesférico. Esto implica una función de base de segundo orden no lineal. El valor de red representa la distancia a un determinado patrón de referencia,

$$\sqrt{\sum_j (p_{ij} - w_{ij})^2}, \text{ con } j = 1, 2, \dots, n \quad (7)$$

1.3.2 Funciones de Activación (*activation function*).

Una neurona biológica puede estar activa (excitada) o inactiva (no excitada); es decir, que tiene un “estado de activación”. Las neuronas artificiales también tienen diferentes estados de activación; algunas de ellas solamente dos, al igual que las biológicas, pero otras pueden tomar cualquier valor dentro de un conjunto determinado.⁷³

La *función activación o transferencia* $f(\text{NET})$ calcula el estado de actividad de una neurona; transformando la entrada global (menos el umbral, U) en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a

⁷³ * MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones.
<http://www.modeladoingenieria.edu.ar/utnfrro/orientacionl/monografias/matich-redesneuronales.pdf>

1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1).*

Hay una infinidad de funciones para ser utilizadas como función de activación en el modelo propuesto, pero se pueden distinguir tres grandes clases: tipo escalón, lineales a trozos, y sigmoide. La elección de la función de activación depende fuertemente del algoritmo de aprendizaje que se vaya a utilizar. Cuando la función de activación es de tipo escalón el elemento de proceso recibe el nombre de perceptrón.

Las funciones de activación más comúnmente utilizadas se detallan a continuación:

3) **Función lineal:**




Figura 62. Función de activación lineal.

Por encima o por debajo de esta zona se fija la salida en 1 o -1, respectivamente. Cuando $x = 1$ (siendo que la misma afecta la pendiente de la gráfica), la salida es igual a la entrada.⁷⁴

⁷⁴ NEURAL NETWORK TOOLBOX, for use with MATLAB,

4) Función sigmoidea:




Figura 63. Función de activación Sigmoidea

Los valores de salida que proporciona esta función están comprendidos dentro de un rango que va de 0 a 1. Al modificar el valor de g se ve afectada la pendiente de la función de activación.

3) Función tangente hiperbólica:





Figura 64. Función de activación tangente Hiperbólica

Los valores de salida de la función tangente hiperbólica están comprendidos dentro de un rango que va de -1 a 1. Al modificar el valor de g se ve afectada la pendiente de la función de activación.

4) Función gaussiana:




$$f(n) = e^{-n^2 / 2\sigma^2} \quad (11)$$

Figura 65. Función de activación gaussiana.

El parámetro σ (de escala) mide la anchura de la gaussiana y equivale al radio de influencia de la neurona en el espacio de entradas: cuanto mayor sea σ mayor es el radio de influencia.

6) Función Escalón:



$$f(n) = \begin{cases} 0 & n < 0 \\ 1 & n \geq 0 \end{cases} \quad (12)$$

Figura 66. Función de activación escalón.

Los valores de salida que proporciona esta función están comprendidos dentro de un rango que va de 0 a 1.

1.3.3 Función de salida (*output function*).

El último componente que una neurona necesita es la *función de salida*. El valor resultante de esta función es la salida de la neurona i (*out_i*); por ende, la función de salida determina que valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente. Normalmente, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango $[0, 1]$ o $[-1, 1]$. También pueden ser binarios $\{0, 1\}$ o $\{-1, 1\}$.⁷⁵

Dos de las funciones de salida más comunes son:

- Ninguna: este es el tipo de función más sencillo, tal que la salida es la misma que la entrada. Es también llamada *función identidad*.
- Binaria:
$$\begin{cases} 1 & \text{si } _{activa} \geq \xi_i \\ 0 & \text{de } _{lo } _{contrario} \end{cases}$$
, donde ξ_i es el umbral.

1.4 Arquitectura de una Red Neuronal Artificial (RNA)

Las neuronas de una determinada red pertenecerán a una de las siguientes clases:⁷⁶

Neuronas de entrada: Reciben las señales exteriores. Integran la primera capa de la red.*

⁷⁵ MATICH, Damián Jorge. Redes Neuronales: Conceptos Básicos y Aplicaciones.

<http://www.modeladoeningenieria.edu.ar/utnfrro/orientacionl/monografias/matich-redesneuronales.pdf>

⁷⁶ * SANTOS, de la Nava Santiago, <http://tejo.usal.es/~nines/d.alumnos/neura/redes.htm#2.3>

Neuronas ocultas: Producen resultados intermedios, no reciben, ni suministran, información al entorno.*

Neuronas de salida: Su salida es observable desde el exterior. Constituyen la última capa de la red.

Muchas veces se habla de arquitectura de una red neuronal. Este concepto se refiere básicamente a la manera en que se interconectan los distintos elementos de proceso que forman la red.

Normalmente los elementos de proceso se organizan como una secuencia de capas con un determinado patrón de interconexión entre los diferentes elementos de proceso que las forman, y con un patrón de conexión entre los elementos de proceso de las distintas capas. Uno de los rasgos que puede ayudar a definir una capa es el hecho de que todos los elementos de proceso que la forman usan la misma función de transferencia.

En muchas de las arquitecturas de redes neuronales se puede hacer la siguiente distinción entre las capas:

- **Capa de entrada.** Es la capa que recibe los estímulos del entorno. No suele tener asociado un mecanismo de aprendizaje, es decir, sus pesos se mantienen constantes, y su misión simplemente es la de distribuir dicha entrada al resto de los elementos de proceso que constituyen la red.
- **Capas ocultas:** son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar

interconectadas de distintas maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.

- **Capa de salida.** Es la capa sobre la que se forman las salidas de la red o dicho de otra manera se transfiere información de la red hacia el exterior.

Una vez vistos los elementos básicos de toda red neuronal se pasará a enumerar las diferentes estructuras en las que estos elementos se pueden asociar. Así se tendrán:

1) Redes Neuronales monocapas (figura 4.). Se corresponde con la red neuronal más sencilla ya que se tiene una capa de neuronas que proyectan las entradas a una capa de neuronas de salida donde se realizan diferentes cálculos. La capa de entrada, por no realizar ningún cálculo, no se cuenta de ahí el nombre de redes neuronales con una sola capa⁷⁷.




Figura 67. Red Neuronal Monocapa

⁷⁷ Redes Neuronales: una breve introducción. Emilio Soria Olivas & A.J. Serrano López.
<http://www.uv.es/~soriae/charla.PDF>

Una aplicación típica de este tipo de redes es su uso como memorias asociativas.

2) Redes Neuronales Multicapa (figura 10.) Es una generalización de la anterior existiendo un conjunto de capas intermedias entre la entrada y la salida (capas ocultas). Este tipo de red puede estar total o parcialmente conectada.⁷⁸




Figura 68. Esquema de una Red Neuronal Multicapa

1.5 Operaciones de capa

Se trata de operaciones que afectan a la capa como un todo. En principio se considerarán las siguientes:

- **Normalización.** Cada elemento de proceso de la capa considerada ajusta su salida para dar un nivel constante de actividad (considerando las salidas de todos los elementos de proceso que forman la capa).

⁷⁸ Redes Neuronales: una breve introducción. Emilio Soria Olivas & A.J. Serrano López.
<http://www.uv.es/~soriae/charla.PDF>

- **Competencia.** Sólo uno o unos pocos elementos de proceso de una capa ganan y producen salida, inhibiendo la generación de las salidas en el resto.

1.6 Clasificación de las RNA's

Por otra parte, dependiendo de la forma en que se estructuren las neuronas y sus conexiones, aparecen dos grandes tipos de redes.⁷⁹

- Redes progresivas.
- Redes realimentadas.

1.6.1 Redes progresivas

Las conexiones de sus neuronas (y, por lo tanto, el flujo de información) son siempre hacia adelante, de la entrada a la salida. No presentan memoria (la respuesta a una entrada determinada es independiente del estado anterior de la red). Por tanto, son estáticas.*

Las arquitecturas progresivas de mayor importancia son el *perceptrón* y las redes de función de base radial (RBF).*

⁷⁹ * Tratamiento digital de voz e imagen. Marcos Faúndez Zanuy. Alfaomega-Marcombo 2001

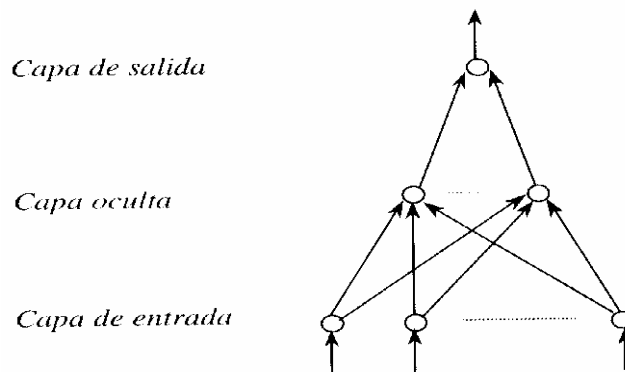


Figura 69. Red progresiva.

1.6.2 Redes realimentadas

A diferencia de las redes progresivas, presentan como mínimo un camino de realimentación, ya sea entre neuronas de una misma capa (conexiones laterales) o como conexión hacia atrás, de una capa exterior a otra más interior.

Son sistemas dinámicos. Cada vez que se presenta una nueva entrada a la red, se calcula la salida de las neuronas. Debido a los lazos de realimentación, las entradas de las neuronas se modifican y la red entra en un nuevo estado.

Las arquitecturas más destacables son:

- Redes competitivas.
- Mapas autoorganizados de Kohonen.
- Red de Hopfield.
- Red de Elmann.
- Modelos ART.




Figura 70. Red realimentada

Es posible considerar también varias opciones en cuanto a la manera en que se realiza la realimentación:

- Realimentación de la salida, si las salidas generadas por la red son realimentadas a las capas anteriores.
- Realimentación del estado, si la realimentación se produce con las salidas producidas en las capas ocultas.

Las redes con realimentación plantean problemas de convergencia y estabilidad, que son en general de difícil análisis.

Otra clasificación de las redes neuronales artificiales puede ser de acuerdo en base a sus conexiones o en base a su aprendizaje.

1.6.3 En base a las conexiones:

- **Redes Feedforward**

Conexiones en un solo sentido (Perceptrón simple y multietapa, Redes de base Radial)

- **Redes recurrentes**

Conexiones en todas las direcciones

- **Redes parcialmente recurrentes**

Unas pocas conexiones recurrentes (Red de Jordan, Red de Elman)

1.6.4 En base al aprendizaje:

Un conjunto de reglas bien definidas que describen el método de adaptación o modificación de los pesos de acuerdo con el entorno en el que se encuentra sumergida la red recibe el nombre de regla de aprendizaje, y su transcripción en forma de procedimiento se denomina algoritmo de aprendizaje.

1.6.4.1 Redes Supervisadas

El aprendizaje supervisado consiste que para cada patrón (ejemplo) presentado a la red existe una respuesta deseada. La respuesta de la red se compara con su salida deseada en base a esa comparación se ajustan los pesos de la red.

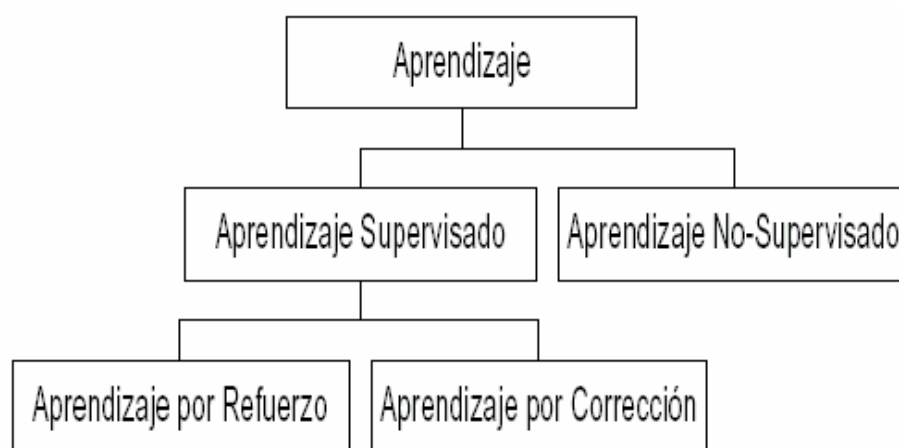


Figura 71. División en los métodos de aprendizaje

En este tipo de aprendizaje se suelen considerar, a su vez, tres formas de llevarlo a cabo, que dan lugar a los siguientes aprendizajes supervisados:

- 1) Aprendizaje por corrección de error.
- 2) Aprendizaje por refuerzo.
- 3) Aprendizaje estocástico.

- **Aprendizaje por Corrección de error**

Los pesos de las conexiones son ajustados en función a la diferencia entre los valores obtenidos y la salida deseada (error cometido en la salida).⁸⁰

$$\Delta w = \alpha y_i (d_j - y_j) \quad (13)$$

Δw = Variación del peso.

α = factor de aprendizaje.

⁸⁰ VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

y_i = salida neurona i.

d_j = Valor de salida deseado neurona j

y_j = Valor de salida obtenido neurona j

La regla de aprendizaje del Perceptrón utiliza este algoritmo. Esta regla solo representa error individual.

Regla delta (error medio), utilizada en las ADALINE y MADALINE:

$$Error_{global} = 1/2P \sum_{k=1}^P \sum_{j=1}^N (y_j - d_j)^2 \quad (14)$$

N = Número de neuronas de salida (ADALINE = 0)

P = Número de informaciones que debe aprender la red.

- **Aprendizaje Estocástico**

Se realizan cambios aleatorios en los valores de los pesos de las conexiones de la red y se evalúa su efecto a partir del objeto deseado y de distribuciones de probabilidad.

Se hace una analogía asociando la red con un sólido físico que inicialmente presenta una temperatura (ruido) y que se va enfriando gradualmente hasta alcanzar el equilibrio térmico (mínima energía).

Se hace un cambio en los pesos y se determina la energía de la red. Si la energía es menor después del cambio (comportamiento se acerca al deseado), se acepta dicho cambio, si no, se aceptaría el cambio en función de una determinada y preestablecida distribución de probabilidades.⁸¹

⁸¹ VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

Otros ejemplos de Algoritmos de Redes Supervisadas son: Redes Feedforward , Redes recurrentes, redes Hopfield, Boltzmann Machine (Hilton, Ackley y Sejnowski – 1984) , Cauchy Machine (Szu- 1986) – más rápida que la anterior.

1.6.4.2 Redes No Supervisadas

El aprendizaje no supervisado no se especifica a la red cual es la respuesta correcta. A través de unas reglas de aprendizaje, la red descubre las relaciones presentes en los ejemplos.

En cuanto a los algoritmos de aprendizaje no supervisado, en general se suelen considerar dos tipos, que dan lugar a los siguientes aprendizajes:

- 1) Aprendizaje hebbiano.
- 2) Aprendizaje competitivo y comparativo.

- **Aprendizaje Hebbiano**

Consiste en el ajuste de los pesos de las conexiones de acuerdo con la correlación (multiplicación en casos de valores binarios +1 y -1) de los valores de activación (salidas) de las dos neuronas conectadas.⁸²

$$\Delta W_{ij} = y_i \cdot y_j \quad (15)$$

Δw = Variación del peso.

y_i = Valor de salida neurona i.

⁸² * VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

y_j = Valor de salida neurona j.

Otra versión de este aprendizaje es el denominado hebbiano diferencial, que utiliza la correlación de las derivadas en el tiempo de las funciones de activación de las neuronas. También hay redes con mecanismos de aprendizaje que resultan de la combinación de la correlación hebbiana con algún otro método, como por ej. la Boltzmann Machine, ya nombrada anteriormente.*

- **Aprendizaje Competitivo y Cooperativo**

Aparentemente debida a T. Kohonen 1988. Se dice que las neuronas compiten (y cooperan) unas entre otras para llevar a cabo una tarea dada. Cuando se presenta a la red cierta información de entrada, sólo una de las neuronas de salida de la red o una por cierto grupo de neuronas se activa (alcanza valor de respuesta máximo). Por esto, las neuronas compiten por activarse, quedando una o una por grupo como vencedora (winner-take-all unit), y quedando anuladas el resto, forzadas a sus valores de respuesta mínimos.

La competición entre neuronas se da en todas las capas de la red, existiendo conexiones recurrentes de autoexcitación y conexiones de inhibición (signo negativo) por parte de las neuronas vecinas. Si es cooperativo, las conexiones con las vecinas serán de excitación.

El objetivo de este aprendizaje es categorizar (clusterizar) los datos que se introducen a la red, así, las informaciones similares son clasificadas formando parte de la misma categoría, y deben activar la misma neurona de salida. Las clases o categorías son creadas por la propia red, ya que se trata de un

aprendizaje no supervisado, a través de las correlaciones entre los datos de entrada.

Otros ejemplos de Algoritmos de Redes No Supervisadas: Kohonen, ART

1.6.4.3 Por refuerzo (entre las dos anteriores).

El instructor o maestro exterior sólo indica cuando la salida es correcta o no, pero no indica en cuanto se diferencia de la salida buscada. Si se compara este paradigma con el supervisado, se observa que si bien el supervisado proporciona una información relativa a la dirección en la que se deben realizar los cambios en el sistema (ajuste de los pesos), en el caso de un aprendizaje por refuerzo no se tiene información acerca de la "dirección" del cambio, lo cual hace que su ámbito de aplicación sea mucho más reducido comparado con el modo supervisado, aunque presenta interés en la comunidad científica dedicada al estudio de las máquinas capaces de aprender.

Ejemplos de Algoritmos por aprendizaje por Refuerzo son: Linear Reward Penalty, ampliado al Associative Reward Penalty, aplicado en redes con conexiones hacia delante de dos capas, Adaptive Heuristic Critic, utilizado en redes feedforward de 3 capas especialmente diseñadas para que una parte de la red sea capaz de generar un valor interno de refuerzo que se aplica a las neuronas de salida de la red.

1.6.4.4 *Aprendizaje híbrido.*

Se trata de una combinación del aprendizaje supervisado y del no supervisado. Parte de los pesos se ajustan por medio de un esquema de aprendizaje supervisado, y el resto se obtienen por medio de un aprendizaje no supervisado.

La teoría del aprendizaje mediante ejemplos conlleva tres aspectos muy importantes a tener en cuenta: determinar la capacidad de aprendizaje, la complejidad de los ejemplos utilizados y la complejidad computacional del proceso en sí:

- **La capacidad** es un concepto relacionado con la cantidad de patrones que pueden ser almacenados y qué funciones y contornos de decisión puede sintetizar una red neuronal artificial.
- **La complejidad de los ejemplos** determina el número de los patrones de aprendizaje necesarios para entrenar la red de tal manera que quede garantizado un determinado grado de generalización. Un escaso número de patrones de aprendizaje comparado con el número de pesos (parámetros libres) puede dar lugar a problemas de sobreentrenamiento (*“overfitting”*).
- **La complejidad computacional** se refiere al tiempo requerido para que el algoritmo de aprendizaje se aproxime a la solución usando los patrones de entrenamiento. Lo más corriente es que los algoritmos de aprendizaje sean computacionalmente muy complejos.

1.6.4.5 Redes neuronales con aprendizaje OFF LINE

Se tienen dos fases, la de aprendizaje y la de funcionamiento, teniendo datos de entrenamiento y datos de prueba. En estas redes, los pesos permanecen fijos después que termina la etapa de entrenamiento. No presentan problemas de estabilidad en su funcionamiento.⁸³

1.6.4.6 Redes neuronales con aprendizaje ON LINE

No se distinguen fases de aprendizaje y de funcionamiento. Los pesos varían dinámicamente cada vez que se presenta nueva información al sistema. Requiere estudio de su estabilidad, debido a su carácter dinámico.*

1.6.5 Según la información de entrada y salida:

En un gran número de redes, tanto los datos de entrada como los de salida son de naturaleza analógica, o sea, son valores reales continuos, normalmente estarán normalizados y su valor absoluto será menor que la unidad.

Otras, por el contrario, solo admiten valores discretos o binarios {0, 1} a su entrada, generando también como salida valores discretos. Tienen función de activación de tipo escalón. Existen también las redes denominadas híbridas, donde las informaciones de entrada son de tipo continuo, pero las salidas de la red son discretas⁸⁴.

⁸³ * VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

⁸⁴ ANEXO B. Figura de: Clasificación de las redes según la información de entrada

1.6.6 Tipo de asociación entre las informaciones de entrada y salida

Existen 2 formas de realizar la asociación entre entrada/salida que se corresponden con la naturaleza de la información almacenada en la red. Una sería la heteroasociación, que se da cuando la red aprende parejas de datos $[(A_1, B_1), \dots, (A_n, B_n)]$, de forma que cuando se tiene una información de entrada A_i , se tendrá como salida asociada B_i . La segunda se conoce como autoasociación, donde la red aprende ciertas informaciones A_1, A_2, \dots, A_n de forma que cuando se presenta una información de entrada se hará una autocorrelación, respondiendo con uno de los datos almacenados, el más parecido al de entrada.⁸⁵

1.6.6.1 Redes Heteroasociativas

Estas redes, al asociar informaciones de entrada con diferentes informaciones de salida, precisan al menos de 2 capas, una para captar y retener la información de entrada y otra para mantener la salida con la información asociada.⁸⁶ En cuanto a su conectividad, hay redes heteroasociativas hacia delante o feedforward (Perceptron, Backpropagation, etc.), redes con conexiones hacia atrás o feedforward/feedback (Art, Bam, etc.) y redes con conexiones laterales. También se tienen redes con sus neuronas dispuestas en capas multidimensionales (Neocognitron, Topology Preserving Map). El

⁸⁵ VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

⁸⁶ * VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

aprendizaje puede ser con supervisión (Perceptrón, Backpropagation, etc.) o sin supervisión (ART, BAM, etc.).*

También pueden clasificarse según el objetivo de su utilización, que puede ser para cómputo de una función general de entrada, o realizar una clasificación, etc. *

1.6.6.2 Redes Autoasociativas

Esta red, asocia una información de entrada con el ejemplar más parecido de los almacenados conocidos por la red. Puede implementarse con una sola capa de neuronas. Si se desea mantener las informaciones de entrada y salida se debe añadir capas adicionales, pero su funcionalidad ya puede conseguirse con una sola capa.

En cuanto a conectividad, se tienen conexiones laterales entre las neuronas (Hopfield, etc.) y, a veces, conexiones autorrecurrentes (salida de una neurona como entrada de la misma).

En relación al tipo de aprendizaje, habitualmente se utiliza el no supervisado (Hopfield, Additive Grossberg, etc.), aunque existe alguna con aprendizaje supervisado (Brain-State-In-a-Box).

Estas redes suelen utilizarse en tareas de filtrado de información, reconstrucción de datos eliminando distorsiones o ruido. También para explorar

relaciones entre informaciones similares, facilitación de búsquedas por contenido en bases de datos y resolución de problemas de optimización.⁸⁷

1.6.7 Modo de Operación

Al hablar de modo de operación se está haciendo referencia a la manera en que la red neuronal procesa los estímulos externos y crea la respuesta de salida. Puede considerarse a una red neuronal como perteneciente a una de dos grandes categorías:

Tabla 61. Clasificación de las RNA's en función de la representación de la información de entrada/salida

REDES CONTINUAS	REDES HÍBRIDAS	REDES DISCRETAS
E: ANALÓGICA S: ANALÓGICA	E: ANALÓGICA S: BINARIA	E: BINARIA S: BINARIA
BACKPROPAGATION	PERCEPTRON	DISCRETE HOPFIELD
BRAIN-STATE-IN-BOX	ADALINE/MADALINE	LEARNING MATRIX
CONTINUOUS HOPFIELD	LINEAR/ASSOCIATIVE REWARD PENALTY	TEMPORAL ASSOCIATIVE MEMORY
LINEAR ASSOCIATIVE MEMORY	ADAPTIVE HEURISTIC CRITIC	BIDIRECTIONAL ASSOCIATIVE MEMORY
OPTIMAL LINEAR ASSOCIATIVE MEMORY		COGNITRON/NEOCOGNITRON
DRIVE-REINFORCEMENT		ADAPTIVE RESONANCE THEORY 1
CONTERPROPAGATION		BOLTZMANN MACHINE
ADDITIVE GROSSBERG		CAUCHY MACHINE
SHUNTING GROSSBERG		
ADAPTIVE BAM		
LEARNING VECTOR QUANTIZER		
TOPOLOGY PRESERVING MAP		
ADAPTIVE RESONANCE THEORY 2		

http://www.pol.una.py/tesis/tesis1/repres-info-e_s.htm

⁸⁷ VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

Tabla 62. Clasificación de las redes neuronales en función del tipo de asociación

REDES HETEROASOCIATIVAS	REDES AUTOASOCIATIVAS
PERCEPTRON	BRAIN-STATE-IN-A-BOX
ADALINE/MADALINE	HOPFIELD
BACKPROPAGATION	OPTIMAL LINEAR ASSOCIATIVE MEMORY
LINEAR REWARD PENALTY	ADDITIVE GROSSBERG
ASSOCIATIVE REWARD PENALTY	SHUNTING GROSSBERG
ADAPTIVE HEURISTIC CRITIC	
BOLTZMANN MACHIN	
CAUCHY MACHINE	
LEARNING MATRIX	
TEMPORAL ASSOCIATIVE MEMORY	
LINEAR ASSOCIATIVE MEMORY	
OPTIMAL LINEAR ASSOCIATIVE MEMORY	
DRIVE-REINFORMCEMENT	
FUZZY ASSOCIATIVE MEMORY	
COUNTERPROPAGATION	
BIDIRECTIONAL ASSOCIATIVE MEMORY	
ADAPTIVE BIDIRECTIONAL ASSOCIATIVE MEMORY	
COGNITRON/NEOCOGNITRON	
TOPOLOGY PRESERVING MAP	
LEARNING VECTOR QUANTITZER	
ADAPTIVE RESONANCE THEORY	

http://www.pol.una.py/tesis/tesis1/asoc_nfo_e_s.htm

1.6.7.1 Redes estáticas.

En este tipo de red una vez establecido el valor de las entradas las salidas alcanzan un valor estacionario independientemente de las entradas en el instante anterior, y en un tiempo siempre por debajo de una determinada cota. Estas redes se pueden caracterizar estructuralmente por la *inexistencia de* bucles de realimentación y de elementos de retardo entre los distintos elementos de proceso que las forman.

Debido a su modo de funcionamiento, estas redes tienen una capacidad limitada para sintetizar funciones dependientes del tiempo en comparación con lo que se expone en el siguiente punto.

1.6.7.2 Redes dinámicas.

Este tipo responde de manera diferente ante diferentes secuencias de entradas, haciendo uso de manera implícita o explícita de la variable *tiempo*. Este aspecto las hace en principios más idóneas que las redes estáticas para la síntesis de funciones en las que aparezca de alguna manera el parámetro tiempo.

La inclusión del elemento tiempo se puede llevar a cabo de varias maneras: síntesis de funciones en las que aparezca de alguna manera el parámetro tiempo.

- Inclusión de manera explícita de un *retardo temporal*, generalmente mediante la superposición de una red estática con unas funciones de retardo (habitualmente un buffer que almacena datos antiguos).

- Uso de una *dinámica de realimentación*. En este tipo de redes sí que existen bucles entre las conexiones de los distintos elementos de proceso (la correspondiente representación mediante grafo contendrá ciclos). Estas realimentaciones pueden ser de muy diferentes tipos, dándose también la posibilidad de que la salida de un elemento de proceso sea utilizada también como una de sus propias entradas.

1.7 Ventajas de las RNA's

A partir de ejemplos, la RNA puede aproximar cualquier función gracias a su aprendizaje adaptativo, aspecto que hace adecuado su uso en problemas de difícil definición analítica.

Los beneficios de las RNAs van mas allá de proporcionar altas velocidades computacionates; ellas poseen una gran capacidad de generalización y adaptabilidad, pueden tomar datos y aprender de ellos. Así ofrecen soluciones a partir de los datos presentados y frecuentemente extraen de ellos hasta la relación más sutil. Estas habilidades difieren radicalmente de las técnicas estándar porque no dependen de programación previa con reglas de conocimiento.

Su alto paralelismo y naturaleza no lineal hace que operaciones independientes puedan ser ejecutadas simultáneamente (en tiempo real), con velocidades mucho más altas que las logradas por otros sistemas desarrollados con programación convencional.

1.8 Redes Neuronales mas conocidas

El Perceptrón

Tabla 63. Características del Perceptrón

Modelo de Red	Topología	Aprendizaje			Asociación Auto/ Hetero	Informac. De Entrada y Salida	Autor(es)
		ON/OFF Line	Supervisa/ No Supervisa	Regla			
Perceptron	2 Capas Feedforward	OFF	Supervisado	Corrección Error	Heteroasociativa	E:Analógica S:Binaria	Rosenblatt 1958

La primera red neuronal conocida, fue desarrollada en 1943 por Warren McCulloch y Walter Pitts; esta consistía en una suma de las señales de entrada, multiplicadas por unos valores de pesos escogidos aleatoriamente. La entrada es comparada con un patrón preestablecido para determinar la salida de la red. Si en la comparación, la suma de las entradas multiplicadas por los pesos es mayor o igual que el patrón preestablecido la salida de la red es uno (1), en caso contrario la salida es cero (0). Al inicio del desarrollo de los sistemas de inteligencia artificial, se encontró gran similitud entre su comportamiento y el de los sistemas biológicos y en principio se creyó que este modelo podía computar cualquier función aritmética o lógica.

La red tipo Perceptrón fue inventada por el psicólogo Frank Rosenblatt en el año 1957. Su intención era ilustrar algunas propiedades fundamentales de los sistemas inteligentes en general, sin entrar en mayores detalles con respecto a condiciones específicas y desconocidas para organismos biológicos concretos. Rosenblatt creía que la conectividad existente en las redes biológicas tiene un elevado porcentaje de aleatoriedad, por lo que se oponía al análisis de McCulloch Pitts en el cual se empleaba lógica simbólica para analizar

estructuras bastante idealizadas. Rosenblatt opinaba que la herramienta de análisis más apropiada era la teoría de probabilidades, y esto lo llevó a una teoría de *separabilidad estadística* que utilizaba para caracterizar las propiedades más visibles de estas redes de interconexión ligeramente aleatorias.

1.8.1.1 Estructura de la red

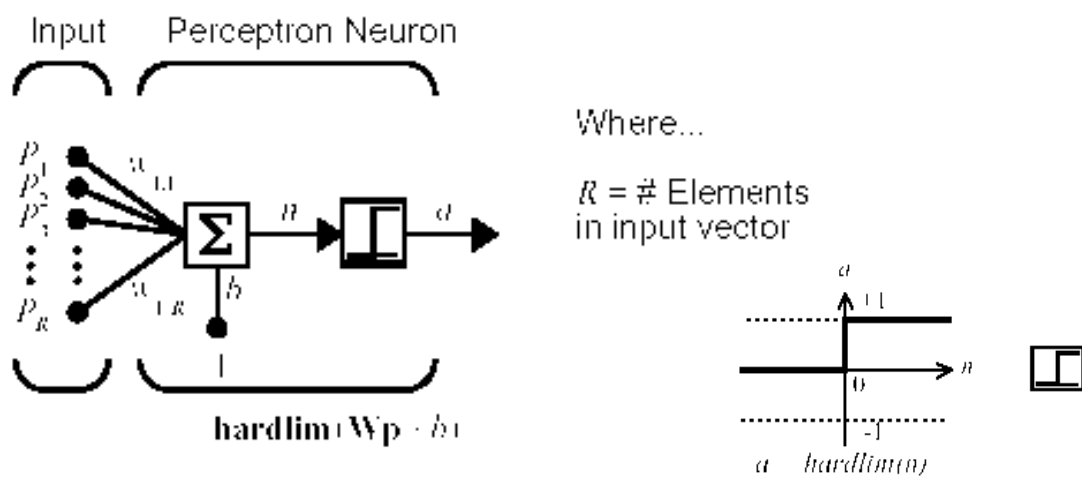


Figura 14. Modelo de neurona Perceptrón y la función de transferencia hard limit

La red puede utilizarse para clasificar los patrones de entrada

$$\text{Si } p_1 \cdot w_1 + p_2 \cdot w_2 + \dots + p_R \cdot w_R + b > 0 \Rightarrow a = 1 \quad (16)$$

$$\text{Si } p_1 \cdot w_1 + p_2 \cdot w_2 + \dots + p_R \cdot w_R + b \leq 0 \Rightarrow a = -1 \quad (17)$$

$$\text{Hiperplano : } p_1 \cdot w_1 + p_2 \cdot w_2 + \dots + p_R \cdot w_R + b = 0 \quad (18)$$

La única neurona de salida del Perceptrón realiza la suma ponderada de las entradas, resta el umbral y pasa el resultado a una función de transferencia de

tipo escalón. La regla e decisión es responder +1 si el patrón presentado pertenece a la clase A, o -1 si el patrón pertenece a la clase B (figura 11.), la salida depende de la entrada neta ($n = \text{suma de las entradas } p_i \text{ ponderadas}$).⁸⁸

La red tipo Perceptrón emplea principalmente dos funciones de transferencia, *hardlim* con salidas 1, 0 o *hardlims* con salidas 1, -1; su uso depende del valor de salida que se espera para la red, es decir si la salida de la red es unipolar o bipolar; sin embargo la función *hardlims* es preferida sobre la *hardlim*, ya que el tener un cero multiplicando algunas de los valores resultantes del producto de las entradas por el vector de pesos, ocasiona que estos no se actualicen y que el aprendizaje sea más lento.*

Una técnica utilizada para analizar el comportamiento de redes como el Perceptrón es presentar en un mapa las regiones de decisión creadas en el espacio multidimensional de entradas de la red, en estas regiones se visualiza qué patrones pertenecen a una clase y cuáles a otra, el Perceptrón separa las regiones por un hiperplano cuya ecuación queda determinada por los pesos de las conexiones y el valor umbral de la función de activación de la neurona, en este caso los valores de los pesos pueden fijarse o adaptarse empleando diferentes algoritmos de entrenamiento.*

Para ilustrar el proceso computacional del Perceptrón consideremos la matriz de pesos en forma general.

⁸⁸ * VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/index.htm>

$$W = \begin{bmatrix} W_{1,1} & W_{1,2} \cdots & W_{1,R} \\ W_{2,1} & W_{2,2} \cdots & W_{2,R} \\ W_{S,1} & W_{S,2} \cdots & W_{S,R} \end{bmatrix} \quad (19)$$

Los pesos para una neurona están representados por un vector compuesto de los elementos de la i -ésima fila de W .

$$W = \begin{bmatrix} W_{i,1} \\ W_{i,2} \\ \vdots \\ W_{i,R} \end{bmatrix} \quad (20)$$

De esta forma y empleando la función de transferencia *hardlim* la salida de la neurona i de la capa de salida

$$a_i = \text{hardlim}(n_i) = \text{hardlim}(w_i^T p_i) \quad (21)$$

1.8.1.2 Limitaciones del perceptrón

Sin embargo, al constar solo de una capa de entrada y otra de salida con una única neurona, tiene una capacidad de representación bastante limitada. Solo es capaz de discriminar patrones muy sencillos, linealmente separables. Ej. : la imposibilidad de representar la función OR-EXCLUSIVA.




Figura 72. El Perceptrón ante fronteras interclase no lineales

1.8.1.3 Regla de Aprendizaje del Perceptrón

Es de tipo supervisado, lo que requiere que sus resultados sean evaluados y se realicen las oportunas modificaciones del sistema si se necesita.⁸⁹

Solo se pueden aprender clasificaciones fáciles, debido a que un Perceptrón usa un separador lineal como célula de decisión, con lo que solo se puede realizar una sola separación lineal (por medio de un hiperplano).

Los pasos de la regla de aprendizaje del Perceptrón son los siguientes:

1- Inicialización de los pesos y del umbral.

Se asignan valores aleatorios a los pesos de las conexiones y al umbral.

2- Presentación de un nuevo par (Entrada, Salida esperada).

Se presenta un par con las entradas. Se pasa la entrada y la salida deseada.

3- Cálculo de la salida actual.

⁸⁹ VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/perceptron.htm>

Cálculo de la función de activación.

4- Adaptación de los pesos.

5- Volver al paso 2.

1.8.2 Perceptrón multicapa

El como se acaba de ver, el Perceptrón sólo puede solucionar problemas linealmente separables que, obviamente, resultan ser un caso muy particular de los problemas reales. La pregunta que surge es si es posible la combinación en varias capas de elementos de proceso tipo Perceptrón, y si es así, cómo se podría entrenar el sistema. Lo que se buscaría con esta combinación de elementos Perceptrón en varias capas es la división del espacio de entradas en varios subespacios, cada uno de ellos representando una característica del problema a tratar. Luego, en capas posteriores se irían delimitando más detalladamente las distintas zonas del espacio de características, así hasta conseguir la salida (partición del espacio de entradas) deseada.

El ajuste de pesos en el Perceptrón se realiza acorde a si la salida generada por dicho elemento de proceso es correcta o no. Cuando se combinan varios Perceptrones formando una estructura en capas, la única que tiene definida de verdad la salida deseada es la capa de salida, y sería entonces la única capa de la red que podría ser ajustada. ¿Qué hacer con las demás capas? La respuesta vino unos cuantos años más tarde con el algoritmo de Retropropagación del Error, que resulta ser una generalización del método del

gradiente decreciente. Pero para poder aplicar la regla del gradiente decreciente es preciso que las funciones involucradas (funciones de transferencia en los elementos de proceso) sean diferenciables. Así, ya no se utilizarán elementos Perceptrón con funciones de activación escalón, puesto que no son diferenciables, sino funciones de tipo sigmoide, que son semejantes al escalón, pero al menos son diferenciables una vez.




Figura 73. Arquitectura del Perceptrón Multicapa.

1.8.2.1 Regiones de decisión del Perceptrón multicapa

Un Perceptrón con tres niveles de neuronas puede formar cualquier región convexa (o cerrada) en ese espacio. Las regiones convexas se forman mediante la intersección entre las regiones formadas por cada neurona de la segunda capa. Cada elemento se comporta como un Perceptrón simple.⁹⁰

⁹⁰ *VARGAS, Saccardo Carolina, SILES, Banks María José. Redes Neuronales Artificiales (Introducción, Características y Ejemplos). <http://www.pol.una.py/tesis/tesis1/perceptron.htm>

Un Perceptrón de cuatro capas puede formar regiones de decisión arbitrariamente complejas. El proceso de separación en clases que se lleva a cabo consiste en la partición de la región deseada en pequeños hipercubos (cuadrados para dos entradas de la red).*

No se requiere más de cuatro capas en una red de tipo Perceptrón, pues, como ya se ha visto anteriormente, puede generar regiones de decisión arbitrariamente complejas. Sólo en ciertos problemas se puede simplificar el aprendizaje mediante el aumento del número de neuronas ocultas.


Estructura	Regiones de Decisión	Problema de la XOR	Clases con Regiones Mezcladas	Formas de Regiones más Generales
1 Capa 	Medio Plano Limitado por un Hiperplano			
2 Capas 	Regiones Cerradas o Convexas			
3 Capas 	Complejidad Arbitraria Limitada por el Número de Neuronas			

Figura 74. Regiones de decisión del Perceptrón multicapa

Tanto en los Perceptrones de tres como en los de cuatro capas, se tiene un inconveniente, que es la selección correcta del número de neuronas de las

capas ocultas. En el de tres capas, este número debería ser lo suficientemente grande como para formar una región con suficiente complejidad par la solución del problema, pero por otro lado, no es conveniente que dicho número de nodos sea tan grande que la estimación de los pesos no sea fiable par el conjunto de patrones de entrada disponibles.

En la práctica, un número de neuronas excesivo en cualquier capa puede generar ruido. Por otro lado, si existe un número de neuronas redundantes se obtiene mayor tolerancia a fallos.

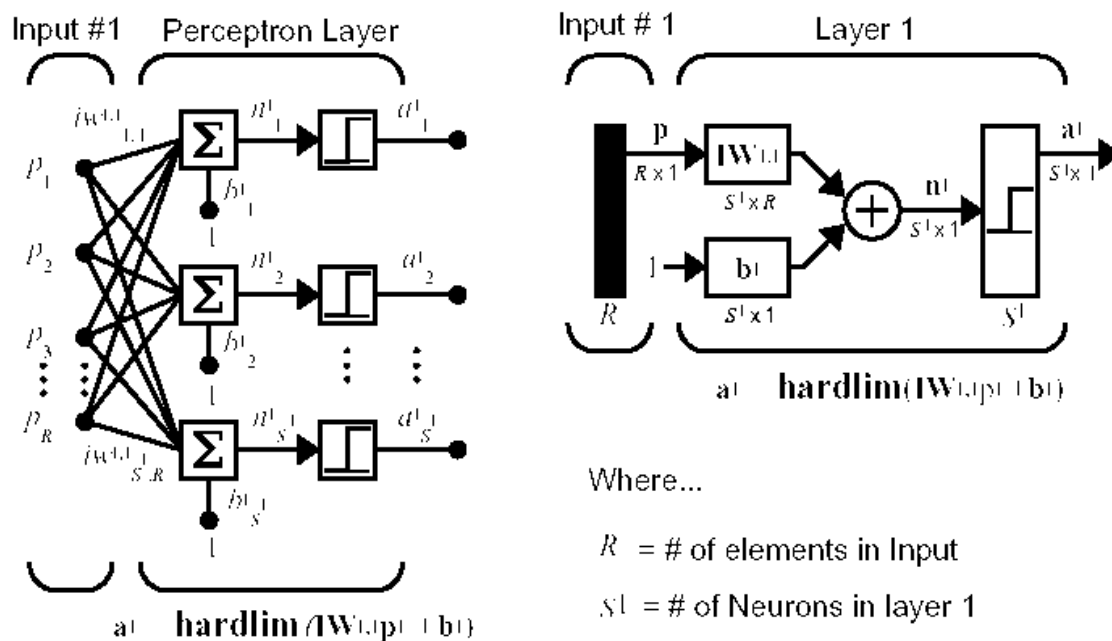


Figura 75. Modelo neuronal del Perceptrón multicapa

1.8.3 Red Backpropagation

Tabla 64. Características de la Red *Backpropagation*

Modelo de Red	Topología	Aprendizaje			Asociación Auto/ Hetero	Informac. De Entrada y Salida	Autor(es)
		ON/OFF Line	Supervisa/ No Supervisa	Regla			
Backpropagation	N Capas Feedforward	OFF	Supervisado	Corrección Error (Regla delta generalizada)	Heteroasociativa	Analógica	Rumelhart, etc. 1986

La regla de aprendizaje del Perceptrón de Rosenblatt y el algoritmo LMS de Widrow y Hoff fueron diseñados para entrenar redes de una sola capa. Como se discutió anteriormente, estas redes tienen la desventaja que solo pueden resolver problemas linealmente separables, fue esto lo que llevó al surgimiento de las redes multicapa para superar esta dificultad en las redes hasta entonces conocidas.⁹¹

El primer algoritmo de entrenamiento para redes multicapa fue desarrollado por Paul Werbos en 1974, este se desarrolló en un contexto general, para cualquier tipo de redes, siendo las redes neuronales una aplicación especial, razón por la cual el algoritmo no fue aceptado dentro de la comunidad de desarrolladores de redes neuronales. Fue solo hasta mediados de los años 80 cuando el algoritmo Backpropagation o algoritmo de propagación inversa fue redescubierto al mismo tiempo por varios investigadores, David Rumelhart, Geoffrey Hinton y Ronal Williams, David Parker y Yann Le Cun. El algoritmo se popularizó cuando fue incluido en el libro "Parallel Distributed Processing Group" por los

⁹¹ ACOSTA, B. María Isabel, ZULUAGA, M. Camilo A., SALAZAR, I. Harold, Tutorial de Redes Neuronales, <http://ohm.utp.edu.co/neuronales/Capitulo2/Backpropagation/AntecedentesB.htm>

psicólogos David Rumelhart y James McClelland. La publicación de este libro trajo consigo un auge en las investigaciones con redes neuronales, siendo la Backpropagation una de las redes más ampliamente empleadas, aun en nuestros días.

1.8.3.1 Estructura de Red

La estructura típica de una red multicapa se observa en la figura 19.




Figura 76. Red Backpropagation de tres capas

Puede notarse que esta red de tres capas equivale a tener tres redes tipo Perceptrón en cascada; la salida de la primera red, es la entrada a la segunda

y la salida de la segunda red es la entrada a la tercera. Cada capa puede tener diferente número de neuronas, e incluso distinta función de transferencia.⁹²

En la figura 2.9 W^1 representa la matriz de pesos para la primera capa, W^2 los pesos de la segunda y así similarmente para todas las capas que incluya una red. Para identificar la estructura de una red multicapa, se empleará una notación abreviada, donde el número de entradas va seguido del número de neuronas en cada capa:

$$R : S^1 : S^2 : S^3 \quad (22)$$

Donde S representa el número de neuronas y el exponente representa la capa a la cual la neurona corresponde.

La notación de la figura 18. es bastante clara cuando se desea conocer la estructura detallada de la red, e identificar cada una de las conexiones, pero cuando la red es muy grande, el proceso de conexión se torna muy complejo y es bastante útil utilizar el esquema de la figura 20.

⁹² ACOSTA, B. María Isabel, ZULUAGA, M. Camilo A., SALAZAR, I. Harold, Tutorial de Redes Neuronales, <http://ohm.utp.edu.co/neuronales/Capitulo2/Backpropagation/EstructuraB.htm>

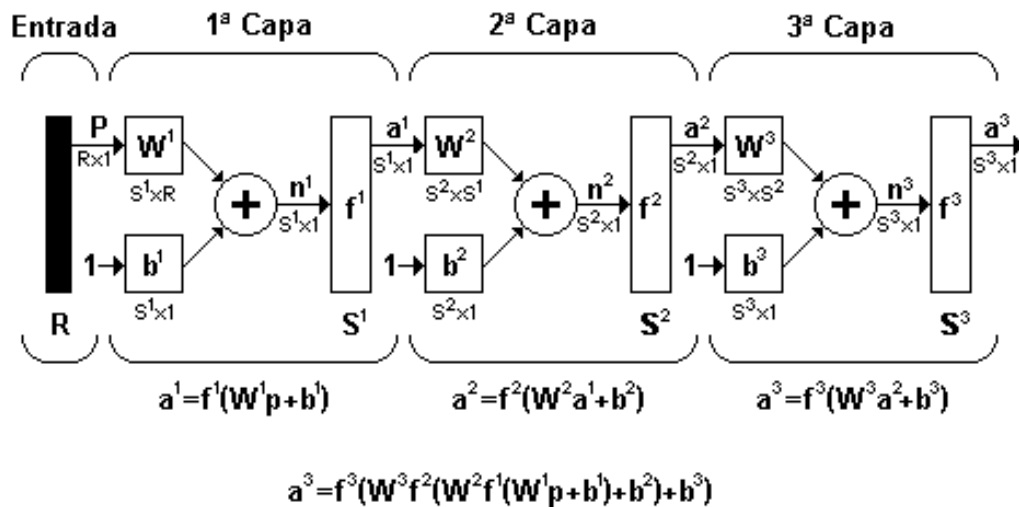


Figura 77. Notación compacta de una red Backpropagation de tres capas

1.8.3.2 Regla de Aprendizaje

El algoritmo Backpropagation para redes multicapa es una generalización del algoritmo LMS, ambos algoritmos realizan su labor de actualización de pesos y ganancias con base en el error medio cuadrático. La red Backpropagation trabaja bajo aprendizaje supervisado y por tanto necesita un set de entrenamiento que le describa cada salida y su valor de salida esperado de la siguiente forma:⁹³

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \quad (23)$$

⁹³ *ACOSTA, B. María Isabel, ZULUAGA, M. Camilo A., SALAZAR, I. Harold, Tutorial de Redes Neuronales, <http://ohm.utp.edu.co/neuronales/Capitulo2/Backpropagation/ReglaB.htm>

Donde p_q es una entrada a la red y t_q es la correspondiente salida deseada para el patrón q -ésimo. El algoritmo debe ajustar los parámetros de la red para minimizar el error medio cuadrático.*

El entrenamiento de una red neuronal multicapa se realiza mediante un proceso de aprendizaje, para realizar este proceso se debe inicialmente tener definida la topología de la red esto es: número de neuronas en la capa de entrada el cual depende del número de componentes del vector de entrada, cantidad de capas ocultas y número de neuronas de cada una de ellas, número de neuronas en la capa de la salida el cual depende del número de componentes del vector de salida o patrones objetivo y funciones de transferencia requeridas en cada capa, con base en la topología escogida se asignan valores iniciales a cada uno de los parámetros que conforma la red.*

Es importante recalcar que no existe una técnica para determinar el número de capas ocultas, ni el número de neuronas que debe contener cada una de ellas para un problema específico, esta elección es determinada por la experiencia del diseñador, el cual debe cumplir con las limitaciones de tipo computacional.

Cada patrón de entrenamiento se propaga a través de la red y sus parámetros para producir una respuesta en la capa de salida, la cual se compara con los patrones objetivo o salidas deseadas para calcular el error en el aprendizaje, este error marca el camino más adecuado para la actualización de los pesos y ganancias que al final del entrenamiento producirán una respuesta satisfactoria a todos los patrones de entrenamiento, esto se logra minimizando el error medio cuadrático en cada iteración del proceso de aprendizaje.

La deducción matemática de este procedimiento se realizará para una red con una capa de entrada, una capa oculta y una capa de salida y luego se generalizará para redes que tengan más de una capa oculta.




Figura 78. Disposición de una red Backpropagation sencilla de 3 capas

Es importante aclarar que en la figura 21.

q : Equivale al número de componentes el vector de entrada.

m : Número de neuronas de la capa oculta

l : Número de neuronas de la capa de salida

Para iniciar el entrenamiento se le presenta a la red un patrón de entrenamiento, el cual tiene q componentes como se describe en la ecuación

(24)

$$P = \begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_i \\ \vdots \\ p_q \end{bmatrix} \quad (24)$$

Cuando se le presenta a la red un patrón de entrenamiento, este se propaga a través de las conexiones existentes produciendo una entrada neta n en cada una de las neuronas de la siguiente capa, la entrada neta a la neurona j de la siguiente capa debido a la presencia de un patrón de entrenamiento en la entrada está dada por la ecuación (24), nótese que la entrada neta es el valor justo antes de pasar por la función de transferencia.⁹⁴

$$n_j^o = \sum_{i=1}^q W_{ji}^o p_i + b_j^o \quad (25)$$

W_{ji}^o : Peso que une la componente i de la entrada con la neurona j de la capa oculta.

p_i : Componente i del vector p que contiene el patrón de entrenamiento de q componentes.

b_j^o : Ganancia de la neurona j de la capa oculta.

Donde el superíndice (o) representa la capa a la que pertenece cada parámetro, en este caso la capa oculta.

⁹⁴ * ACOSTA, B. María Isabel, ZULUAGA, M. Camilo A., SALAZAR, I. Harold, Tutorial de Redes Neuronales, <http://ohm.utp.edu.co/neuronales/Capitulo2/Backpropagation/ReglaB.htm>

Cada una de las neuronas de la capa oculta tiene como salida a_j^o que esta dada por la ecuación (26)

$$a_j^o = f^o \left(\sum_{i=1}^q W_{ji}^o p_i + b_j^o \right) \quad (26)$$

f^o : Función de transferencia de las neuronas de la capa oculta

Las salidas a_j^o de las neuronas de la capa oculta (de l componentes) son las entradas a los pesos de conexión de la capa de salida, este comportamiento esta descrito por la ecuación (27)

$$n_k^s = \sum_{j=1}^m W_{kj}^s a_j^o + b_k^s \quad (27)$$

W_{kj}^s : Peso que une la neurona j de la capa oculta con la neurona k de la capa de salida, la cual cuenta con s neuronas

a_j^o : Salida de la neurona j de la capa oculta, la cual cuenta con m neuronas.

b_k^s : Ganancia de la neurona k de la capa de salida.

n_k^s : Entrada neta a la neurona k de la capa de salida.

La red produce una salida final descrita por la ecuación (28)

$$a_k^s = f^s(n_k^s) \quad (28)$$

f^s : Función de transferencia de las neuronas de la capa de salida.

Reemplazando (27) en (28) se obtiene la salida de la red en función de la entrada neta y de los pesos de conexión con la última capa oculta

$$\mathbf{a}_k^S = f^S \left(\sum_{j=1}^m W_{kj}^S \mathbf{a}_j^o + b_k^S \right) \quad (29)$$

La salida de la red de cada neurona \mathbf{a}_k^S se compara con la salida deseada t_k para calcular el error en cada unidad de salida (30)

$$\delta_k = (t_k - \mathbf{a}_k^S) \quad (30)$$

El error debido a cada patrón p propagado está dado por (31)

$$ep^2 = \frac{1}{2} \sum_{k=1}^S (\delta_k)^2 \quad (31)$$

ep^2 : Error medio cuadrático para cada patrón de entrada p

δ_k : Error en la neurona k de la capa de salida con l neuronas

Este proceso se repite para el número total de patrones de entrenamiento (r), para un proceso de aprendizaje exitoso el objetivo del algoritmo es actualizar todos los pesos y ganancias de la red minimizando el error medio cuadrático total descrito en (32).

$$\mathbf{e}^2 = \sum_{p=1}^r ep^2 \quad (32)$$

\mathbf{e}^2 : Error total en el proceso de aprendizaje en una iteración luego de haber presentado a la red los r patrones de entrenamiento.

El error que genera una red neuronal en función de sus pesos, genera un espacio de n dimensiones, donde n es el número de pesos de conexión de la red, al evaluar el gradiente del error en un punto de esta superficie se obtendrá la dirección en la cual la función del error tendrá un mayor crecimiento, como el objetivo del proceso de aprendizaje es minimizar el error debe tomarse la dirección negativa del gradiente para obtener el mayor decremento del error y de esta forma su minimización, condición requerida para realizar la actualización de la matriz de pesos en el algoritmo Backpropagation:

$$W_{k+1} = W_k - \alpha \nabla ep^2 \quad (33)$$

El gradiente negativo de ep^2 se denotara como $-\nabla ep^2$ y se calcula como la derivada del error respecto a todos los pesos de la red.

En la capa de salida el gradiente negativo del error con respecto a los pesos

$$\text{es: } -\frac{\partial ep^2}{\partial W_{kj}^S} = -\frac{\partial}{\partial W_{kj}^S} \left(\frac{1}{2} \sum_{k=1}^I (t_k - a_k^S)^2 \right) = (t_k - a_k^S) \times \frac{\partial a_k^S}{\partial W_{kj}^S} \quad (34)$$

$-\frac{\partial ep^2}{\partial W_{kj}^S}$: Componente del gradiente $-\nabla ep^2$ respecto al peso de la conexión de la neurona de la capa de salida y la neurona j de la capa oculta W_{kj}^S .

$\frac{\partial a_k^S}{\partial W_{kj}^S}$: Derivada de la salida de la neurona k de la capa de salida respecto, al peso W_{kj}^S .

Para calcular $\frac{\partial a_k^S}{\partial W_{kj}^S}$ se debe utilizar la regla de la cadena, pues el error no es una función explícita de los pesos de la red, de la ecuación (28) puede verse que la salida de la red a_k^S esta explícitamente en función de n_k^S y de la ecuación (34) puede verse que n_k^S sta explícitamente en función de W_{kj}^S , considerando esto se genera la ecuación (41).

$$\frac{\partial a_k^S}{\partial W_{kj}^S} = \frac{\partial a_k^S}{\partial n_k^S} \times \frac{\partial n_k^S}{\partial W_{kj}^S} \quad (35)$$

Tomando la ecuación (42) y reemplazándola en la ecuación (34) se obtiene,

$$-\frac{\partial ep^2}{\partial W_{kj}^S} = (t_k - a_k^S) \times \frac{\partial a_k^S}{\partial n_k^S} \times \frac{\partial n_k^S}{\partial W_{kj}^S} \quad (36)$$

$\frac{\partial n_k^S}{\partial W_{kj}^S}$: Derivada de la entrada neta a la neurona k de la capa de salida

respecto a los pesos de la conexión entre las neuronas de la capa oculta y la capa de salida.

$\frac{\partial a_k^S}{\partial n_k^S}$: Derivada de la salida de la neurona k de la capa de salida respecto a su entrada neta.

Reemplazando en la ecuación (36) las derivadas de las ecuaciones (27) y (28)

se obtiene

$$-\frac{\partial ep^2}{\partial W_{kj}^S} = (t_k - a_k^S) \times f'^S(n_k^S) \times a_j^o \quad (37)$$

Como se observa en la ecuación (37) las funciones de transferencia utilizadas en este tipo de red deben ser continuas para que su derivada exista en todo el intervalo, ya que el término $f'^s(n_k^s)$ es requerido para el cálculo del error.

Las funciones de transferencia f más utilizadas y sus respectivas derivadas son las siguientes:




Figura 79. Función de activación Sigmoidea

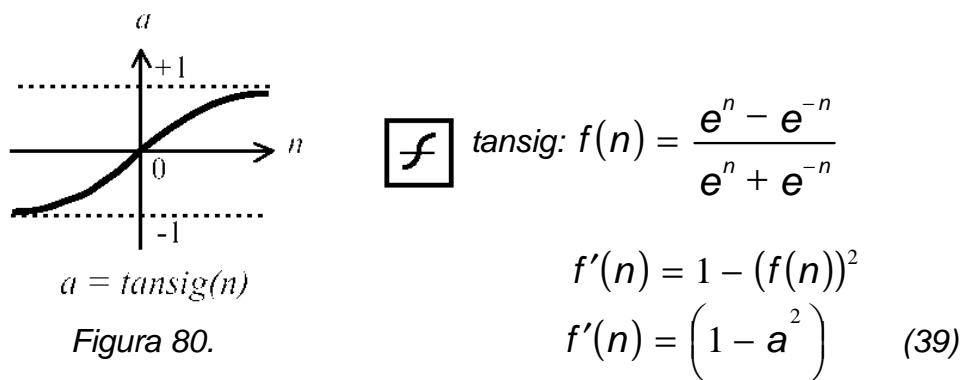


Figura 80.




Figura 81. Función de activación lineal.

De la ecuación (37), los términos del error para las neuronas e la capa de salida están dados por la ecuación (41), la cual se le denomina comúnmente sensitiva de la capa de salida.

$$\delta_k^S = (t_k - a_k^S) f'^S(n_k^S) \quad (41)$$

Este algoritmo se denomina Backpropagation o de propagación inversa debido a que el error se propaga de manera inversa al funcionamiento normal de la red, de esta forma, el algoritmo encuentra el error en el proceso de aprendizaje desde las capas más internas hasta llegar a la entrada; con base en el cálculo de este error se actualizan los pesos y ganancias de cada capa.

Después de conocer (41) se procede a encontrar el error en la capa oculta el cual esta dado por:

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = -\frac{\partial}{\partial W_{ji}^o} \left(\frac{1}{2} \sum_{k=1}^l (t_k - a_k^S) \right) = \sum_{k=1}^l (t_k - a_k^S) \times \frac{\partial a_k^S}{\partial W_{ji}^o} \quad (42)$$

Para calcular el último término de la ecuación (42) se debe aplicar la regla de la cadena en varias ocasiones como se observa en la ecuación (43) puesto que la salida de la red no es una función explícita de los pesos de la conexión entre la capa de entrada y la capa oculta.

$$\frac{\partial a_k^S}{\partial W_{ji}^o} = \frac{\partial a_k^S}{\partial n_k^S} \times \frac{\partial n_k^S}{\partial n_k^o} \times \frac{\partial n_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o} \quad (43)$$

Todos los términos de la ecuación (44) son derivados respecto a variables de las que dependan explícitamente, reemplazando (42) en (43) tenemos:

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^I (t_k - a_k^s) \times \frac{\partial a_k^s}{\partial n_k^s} \times \frac{\partial n_k^s}{\partial n_k^o} \times \frac{\partial n_k^o}{\partial n_j^o} \times \frac{\partial n_j^o}{\partial W_{ji}^o} \quad (44)$$

Tomando las derivadas de las ecuaciones (25) (26) (27) (28) y reemplazándolas en la ecuación (44) se obtiene la expresión del gradiente del error en la capa oculta

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^I (t_k - a_k^s) \times f'^s(n_k^s) \times W_{kj}^s \times f'^o(n_j^o) \times p_i \quad (45)$$

Reemplazando la ecuación (42) en la ecuación (45) se tiene:

$$-\frac{\partial ep^2}{\partial W_{ji}^o} = \sum_{k=1}^I \delta_k^s \times W_{kj}^s \times f'^o(n_j^o) \times p_i \quad (46)$$

Los términos del error para cada neurona de la capa oculta esta dado por la ecuación (47), este término también se denomina sensibilidad de la capa oculta.

$$\delta_j^o = f'^o(n_j^o) \times \sum_{k=1}^I \delta_k^s W_{kj}^s \quad (47)$$

Luego de encontrar el valor del gradiente del error se procede a actualizar los pesos de todas las capas empezando por la de salida, para la capa de salida la actualización de pesos y ganancias esta dada por (48) y (49).

$$W_{kj}(t+1) = W_{kj}(t) - 2\alpha \delta_k^s \quad (48)$$

$$b_k(t+1) = b_k(t) - 2\alpha \delta_k^s \quad (49)$$

α : Rata de aprendizaje que varía entre 0 y 1 dependiendo de las características del problema a solucionar.

Luego de actualizar los pesos y ganancias de la capa de salida se procede a actualizar los pesos y ganancias de la capa oculta mediante las ecuaciones (50) y (51)

$$W_{ji}(t+1) = W_{ji}(t) - 2\alpha \delta_j^o p_i \quad (50)$$

$$b_j(t+1) = b_j(t) - 2\alpha \delta_j^o \quad (51)$$

Esta deducción fue realizada para una red de tres capas, si se requiere realizar el análisis para una red con dos o más capas ocultas, las expresiones pueden derivarse de la ecuación (47) donde los términos que se encuentran dentro de la sumatoria pertenecen a la capa inmediatamente superior, este algoritmo es conocido como la regla Delta Generalizada desarrollada por Rumelhart D., la cual es una extensión de la regla delta desarrollada por Widrow en 1930.

Para algunos autores las sensibilidades de las capas están denotadas por la letra **S**, reescribiendo las ecuaciones (41) y (47) con esta notación se obtienen las ecuaciones (52) y (53)

$$S^M = -2 f^M(n^M)(t - a) \quad (52)$$

$$s^M = f^m(n^m)(W^{m+1})^T s^{m+1}, \text{ para } m = M-1, \dots, 2, 1. \quad (53)$$

En la ecuación (52) M representa la última capa y S^M la sensibilidad para esta capa, la ecuación (53) expresa el cálculo de la sensibilidad capa por capa comenzando desde la última capa oculta, cada uno de estos términos involucra que el término para la sensibilidad de la capa siguiente ya este calculado.

Como se ve el algoritmo Backpropagation utiliza la misma técnica de aproximación en pasos descendientes que emplea el algoritmo LMS, la única complicación está en el cálculo del gradiente, el cual es un término indispensable para realizar la propagación de la sensibilidad.

En las técnicas de gradiente descendiente es conveniente avanzar por la superficie de error con incrementos pequeños de los pesos; esto se debe a que tenemos una información local de la superficie y no se sabe lo lejos o lo cerca que se está del punto mínimo, con incrementos grandes, se corre el riesgo de pasar por encima del punto mínimo, con incrementos pequeños, aunque se tarde más en llegar, se evita que esto ocurra. El elegir un incremento adecuado influye en la velocidad de convergencia del algoritmo, esta velocidad se controla a través de la tasa de aprendizaje α , la que por lo general se escoge como un número pequeño, para asegurar que la red encuentre una solución. Un valor pequeño de α significa que la red tendrá que hacer un gran número de iteraciones, si se toma un valor muy grande, los cambios en los pesos serán muy grandes, avanzando muy rápidamente por la superficie de error, con el

riesgo de saltar el valor mínimo del error y estar oscilando alrededor de él, pero sin poder alcanzarlo.⁹⁵

Es recomendable aumentar el valor de α una medida que disminuye el error de la red durante la fase de entrenamiento, para garantizar así una rápida convergencia, teniendo la precaución de no tomar valores demasiado grandes que hagan que la red oscile alejándose demasiado del valor mínimo. Algo importante que debe tenerse en cuenta, es la posibilidad de convergencia hacia alguno de los mínimos locales que pueden existir en la superficie del error del espacio de pesos como se ve en la figura 25.*




Figura 82. Superficie típica de error

En el desarrollo matemático que se ha realizado para llegar al algoritmo Backpropagation, no se asegura en ningún momento que el mínimo que se encuentre sea global, una vez la red se asiente en un mínimo sea local o global cesa el aprendizaje, aunque el error siga siendo alto. En todo caso, si la solución es admisible desde el punto de vista del error, no importa si el mínimo

⁹⁵ * ACOSTA, B. María Isabel, ZULUAGA, M. Camilo A., SALAZAR, I. Harold, Tutorial de Redes Neuronales, <http://ohm.utp.edu.co/neuronales/Capitulo2/Backpropagation/ReglaB.htm>

es local o global o si se ha detenido en algún momento previo a alcanzar un verdadero mínimo.

1.8.3.3 Red Backpropagation con momentum

Esta modificación está basada en la observación de la última sección de la gráfica del error medio cuadrático en el proceso de convergencia típico para una red Backpropagation; este proceso puede verse en la figura 26. en la cual se nota la caída brusca del error en la iteración para la cual alcanza convergencia.⁹⁶




Figura 83. Comportamiento típico del proceso de convergencia para una red Backpropagation

Este comportamiento puede causar oscilaciones no deseadas, por lo que es conveniente suavizar esta sección de la gráfica incorporando un filtro pasa-bajo

⁹⁶ * ACOSTA, B. María Isabel, ZULUAGA, M. Camilo A., SALAZAR, I. Harold, Tutorial de Redes Neuronales, <http://ohm.utp.edu.co/neuronales/Capitulo2/Backpropagation/ReglaB.htm>

al sistema. Para ilustrar el efecto positivo del filtro en el proceso de convergencia, se analizará el siguiente filtro de primer orden:

$$y(k) = \gamma y(k-1) + (1-\gamma)w(k) \quad (54)$$

Donde $w(k)$ es la entrada el filtro, $y(k)$ su salida y γ es el coeficiente de momentum que está en el intervalo $0 \leq \gamma \leq 1$.

Recordando los parámetros de actualización empleados por el algoritmo Backpropagation tradicional:

$$\Delta W^m(k) = -\alpha s^m (s^{m-1})^T \quad (55)$$

$$\Delta b^m(k) = -\alpha s^m \quad (56)$$

Al adicionar el filtro con momentum a este algoritmo de actualización, se obtienen las siguientes ecuaciones que representan el algoritmo Backpropagation con momentum:

$$\Delta W^m(k) = \gamma \Delta W^m(k-1) - (1-\gamma)\alpha s^m (a^{m-1})^T \quad (57)$$

$$\Delta b^m(k) = \gamma \Delta b^m(k-1) - (1-\gamma) - \alpha s^m \quad (58)$$

Este algoritmo, hace que la convergencia sea estable e incluso más rápida, además permite utilizar una tasa de aprendizaje alta.

La figura 27. referencia el comportamiento del algoritmo con momentum en el punto de convergencia:




Figura 84. Trayectoria de convergencia con momentum

1.8.3.4 Método del Gradiente Conjugado

Este algoritmo no involucra el cálculo de las segundas derivadas de las variables y converge al mínimo de la función cuadrática en un número finito de iteraciones. El algoritmo del gradiente conjugado, sin aplicarlo aún al algoritmo de propagación inversa consiste en:

1. Seleccionar la dirección de p_0 , la condición inicial, en el sentido negativo del gradiente:

$$p_0 = -g_0 \quad (59)$$

Donde

$$g(k) \equiv \nabla e(x) \Big|_{x=x_k} \quad (60)$$

2. Seleccionar la tasa de aprendizaje α_k para minimizar la función a lo largo de la dirección

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k \quad (61)$$

3. Seleccionar la dirección siguiente de acuerdo a la ecuación

$$\mathbf{p}_k = -\mathbf{g}_k + \beta_k \mathbf{p}_{k-1} \quad (62)$$

con

$$\beta_k = \frac{\Delta \mathbf{g}_{k-1}^T \mathbf{g}_k}{\Delta \mathbf{g}_{k-1}^T \mathbf{p}_{k-1}} \quad \text{o} \quad \beta_k = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}} \quad (63)$$

4. Si el algoritmo en este punto aún no ha convergido, regresamos al numeral 2

Este algoritmo no puede ser aplicado directamente a una red neural porque el error no es una función cuadrática; lo que afecta al algoritmo en dos formas, primero no es hábil para minimizar la función a lo largo de una línea como es requerido en el paso 2; segundo, el error mínimo no será alcanzado normalmente en un número finito de pasos y por esto el algoritmo necesitará ser inicializado después de un número determinado de iteraciones.

A pesar de estas complicaciones, esta modificación del algoritmo Backpropagation converge en muy pocas iteraciones, y es incluso uno de los algoritmos más rápidos para redes multicapa, como puede notarse en la figura 28.




Figura 85. Trayectoria del Gradiente Conjugado

1.8.3.5 Algoritmo de Levenberg – Marquardt

Este algoritmo es una modificación del método de Newton, el que fue diseñado para minimizar funciones que sean la suma de los cuadrados de otras funciones no lineales; es por ello que el algoritmo de Levenberg - Marquardt, tiene un excelente desempeño en el entrenamiento de redes neuronales donde el rendimiento de la red esté determinado por el error medio cuadrático.

El método de Newton para optimizar el rendimiento $e(x)$ es:

$$X_{k+1} = X_k - A_k^{-1} g_k \quad (64)$$

$$A_k \equiv \nabla^2 e(x) \Big|_{x=x_k} \quad g_k \equiv \nabla e(x) \Big|_{x=x_k} \quad (65)$$

Si asumimos que $e(x)$ es una suma de funciones cuadráticas:

$$e(\mathbf{x}) = \sum_{i=1}^n v_i^2(\mathbf{x}) = \mathbf{v}^T(\mathbf{x})\mathbf{v}(\mathbf{x}) \quad (66)$$

El gradiente puede ser escrito entonces en forma matricial:

$$\nabla e(\mathbf{x}) = 2 \mathbf{J}^T(\mathbf{x})\mathbf{v}(\mathbf{x}) \quad (67)$$

Donde $\mathbf{J}(\mathbf{x})$ es la matriz Jacobiana.

Ajustando el método de Newton, obtenemos el algoritmo de Levenberg Marquardt

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(\mathbf{x}_k)\mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k)\mathbf{v}(\mathbf{x}_k) \quad (68)$$

o

$$\Delta \mathbf{x}_k = -[\mathbf{J}^T(\mathbf{x}_k)\mathbf{J}(\mathbf{x}_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k)\mathbf{v}(\mathbf{x}_k) \quad (69)$$

La nueva constante μ determina la tendencia del algoritmo, cuando μ_k se incrementa, este algoritmo se aproxima al algoritmo de pasos descendientes para tasas de aprendizaje muy pequeñas; cuando μ_k se decreta este algoritmo se convierte en el método de Gauss – Newton.

El algoritmo comienza con un valor pequeño para μ_k , por lo general 0.01, si en ese paso no se alcanza el valor para $e(\mathbf{x})$ entonces el paso es repetido con μ_k multiplicado por un factor $\vartheta > 1$. Si se ha escogido un valor pequeño de paso en la dirección de paso descendiente, $e(\mathbf{x})$ debería decrecer. Si un paso produce un pequeño valor para $e(\mathbf{x})$, entonces el algoritmo tiende al método de

Gauss - Newton, el que se supone garantiza una rápida convergencia. Este algoritmo genera un compromiso entre la velocidad del método de Gauss-Newton y la garantía de convergencia del método de paso descendiente.

Los elementos de la matriz Jacobiana necesarios en el algoritmo de Levenberg-Marquardt son de este estilo:

$$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial x_l} \quad (70)$$

Donde x es el vector de parámetros de la red, que tiene la siguiente forma:

$$x^T = [x_1, x_2, \dots, x_n] = \left[w_{1,1}^1, w_{1,2}^1, \dots, w_{S^1,R}^1, b_1^1, \dots, b_{S^1}^1 \right] \quad (71)$$

Para utilizar este algoritmo en las aplicaciones para redes multicapa, se redefinirá el término sensibilidad de forma que sea más simple hallarlo en cada iteración.

$$s_{i,h}^m \equiv \frac{\partial e_{k,q}}{\partial n_{i,q}^m} \quad (72)$$

Donde $h = (q - 1)S^M + k$

Con la sensibilidad definida de esta manera, los términos de la matriz Jacobiana pueden ser calculados más fácilmente:

$$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial w_{i,j}^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} * \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = s_{i,h}^m * \frac{\partial n_{i,q}^m}{\partial w_{i,j}^m} = s_{i,h}^m * \alpha_{j,q}^{m-1} \quad (73)$$

y para las ganancias:

$$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial b_i^m} = \frac{\partial e_{k,q}}{\partial n_{i,q}^m} * \frac{\partial n_{i,q}}{\partial b_i^m} = s_{i,h}^m * \frac{\partial n_{i,q}}{\partial b_i^m} = s_{i,h}^m \quad (74)$$

De esta forma, cuando la entrada p_Q ha sido aplicada a la red y su correspondiente salida a^M_Q ha sido computada, el algoritmo Backpropagation de Levenberg-Marquardt es inicializado con:

$$S_q^M = -f^M \left(n_q^M \right) \quad (75)$$

Cada columna de la matriz S_q^M debe ser propagada inversamente a través de la red para producir una fila de la matriz Jacobiana. Las columnas pueden también ser propagadas conjuntamente de la siguiente manera:

$$S_q^M = f^m \left(n_q^m \right) (W^{m+1}) S_q^{m+1} \quad (76)$$

Las matrices de sensibilidad total para cada capa en el algoritmo de Levenberg-Marquardt son formadas por la extensión de las matrices computadas para cada entrada:

$$S^m = \left[S_1^m \right] \left[S_1^m \right] \cdots \left[S_Q^m \right] \quad (77)$$

Para cada nueva entrada que es presentada a la red, los vectores de sensibilidad son propagados hacia atrás, esto se debe a que se ha calculado

cada error en forma individual, en lugar de derivar la suma al cuadrado de los errores. Para cada entrada aplicada a la red habrá S^M errores, uno por cada elemento de salida de la red y por cada error se generara una fila de la matriz Jacobiana.

Este algoritmo puede resumirse de la siguiente manera:

1. Se presentan todas las entradas a la red, se calculan las correspondientes salidas y cada uno de los errores según

$$e_q = t_q - a_q^M \quad (78)$$

se calcula después, la suma de los errores cuadrados para cada entrada $e(x)$

2. Se calculan las sensitividades individuales y la matriz sensibilidad total y con estas, se calculan los elementos de la matriz Jacobiana.
3. Se obtiene Δx_k
4. Se recalcula la suma de los errores cuadrados usando $x_k + \Delta x_k$. Si esta nueva suma es más pequeña que el valor calculado en el paso 1 entonces se divide μ por β , se calcula $x_{k+1} = x_k + \Delta x_k$ y se regresa al paso 1. Si la suma no se reduce entonces se multiplica μ por β

Y se regresa al paso 3.

El algoritmo debe alcanzar convergencia cuando la norma del gradiente de

$$\nabla e(x) = 2 J^T(x)v(x) \quad (79)$$

sea menor que algún valor predeterminado, o cuando la suma de los errores cuadrados ha sido reducida a un error que se haya trazado como meta.

El comportamiento de este algoritmo se visualiza en la figura 33., la cual muestra la trayectoria de convergencia con $\mu = 0,01$ y $\lambda = 5$

Como puede verse, este algoritmo converge en menos iteraciones que cualquier método discutido anteriormente, por supuesto requiere mucha más computación por iteración, debido a que implica el cálculo de matrices inversas. A pesar de su gran esfuerzo computacional sigue siendo el algoritmo de entrenamiento más rápido para redes neuronales cuando se trabaja con un moderado número de parámetros en la red, si el número de parámetros es muy grande utilizarlo resulta poco práctico.




Figura 86. Trayectoria del algoritmo Levenberg-Marquardt

1.8.4 Redes de Base Radial

Tabla 65. Características de las Redes de Base Radial

Modelo de Red	Topología	Aprendizaje			Asociación Auto/Hetero	Informac. De Entrada y Salida	Autor(es)
		ON/OFF Line	Supervisa/ No Supervisa	Regla			
Redes Base Radial	N Capas Feedforward	OFF	Híbrido	Corrección Error y competitivo	Auto-organizado	Analógica	Moody, Poggio. 1990

Diseño de redes neuronales con una “curve fitting” aproximación del problema en un alto espacio dimensional. Acorde con este punto de vista el conocimiento o aprendizaje es equivalente a definir una superficie en un espacio multidimensional que proporciona un mejor entrenamiento de datos, con el criterio “best fit” (mejor- apropiado) es medido en algún sentido estadístico. Correspondientemente la generalización es equivalente para el uso de esta superficie multidimensional para la interpolación en el test de datos. Tal punto de vista es la motivación detrás del método de “radial – basis functions” en el sentido estas gráficas sobre trabajo de investigar en la estricta interpolación tradicional en un espacio multidimensional.

1.8.4.1 Modelo Neuronal de las RBFs

Redes de base Radial pueden requerir mas neuronas que el estándar feed-forwards o redes backpropagation, pero ellas pueden ser diseñadas en una fracción del tiempo que toma entrenar el estándar de redes feed-forward.




Figura 87. Redes de Base Radial con R entradas

El resultado entre la entrada y la función de transferencia (radbas) es el vector distancia entre le vector \mathbf{w} pesos y el vector de entrada \mathbf{p} , multiplicado por el bias b . (La caja $\| \text{dist} \|$ en esta figura acepta el vector input \mathbf{p} y la única fila de la matriz de pesos y produce el producto punto de los dos).

La función de transferencia para una neurona de base radial es:

$$\text{radbas}(n) = e^{-n^2} \quad (80)$$

Aquí esta la gráfica de la radbas función de transferencia.

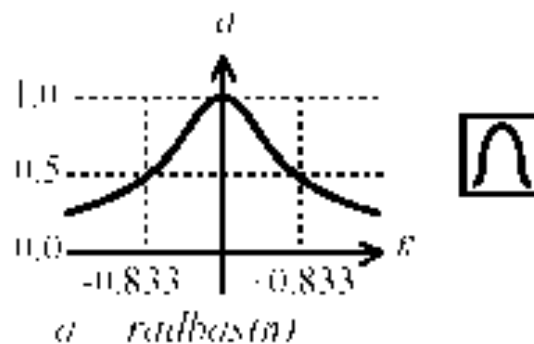


Figura 88. Función de Base Radial

La FBR tienen un máximo de 1 cuando esta entrada (input) es 0. Como la distancia entre w y p decrece, la salida (output) incrementa. De este modo una neurona de base radial actúa como un detector que produce 1 cada vez que la entrada p es idéntica al vector peso.

1.8.4.2 Estructura de red

Una red RBF tiene tres capas: de entrada, una capa oculta de S^1 neuronas y una capa de salida de S^2 neuronas.

La diferencia está en las neuronas ocultas: operan en base a la distancia que separa el vector de entrada del vector de pesos de la neurona (centroide). A esta distancia le aplican una función gaussiana.

Las neuronas de salida son lineales.

En el RBF, la respuesta de las neuronas de la capa oculta es localizada: solamente responden a entradas cercanas a su centroide.

La estructura general es:




Figura 89. Estructura general de una Red de Base Radial.

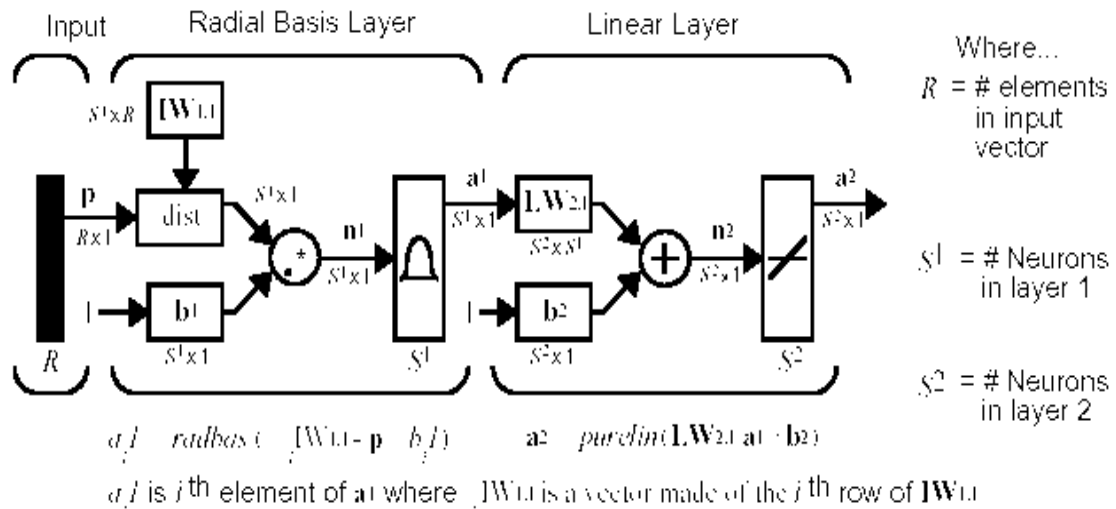


Figura 90. Arquitectura de Red Neuronal de RBF: La *dist* caja en esta figura acepta la entrada vector \mathbf{p} y la entrada la matriz de pesos $\mathbf{IW}^{1,1}$, y produce un vector que tiene S^1 elementos. Los elementos son la distancia entre el vector entrada y vector $\mathbf{IW}^{1,1}$ formado desde las filas de la matriz de pesos.

Las neuronas de la capa oculta calculan la distancia r de su vector de pesos (centroide) al vector de entrada \mathbf{x} . La salida de la neurona se calcula a partir de una función de activación llamada función radial. La más empleada es la función gaussiana:

$$\Phi(r) = e^{-r^2 / 2\sigma^2} \quad (81)$$

El parámetro σ (de escala) mide la anchura de la gaussiana y equivale al radio de influencia de la neurona en el espacio de entradas: cuanto mayor sea σ mayor es el radio de influencia.

Así, la salida de la neurona j de la capa oculta será:

$$z_j = e^{-r_j^2 / 2\sigma_j^2} \quad (82)$$

Si el vector de entrada x coincide con el centroide de la neurona j , r_j será muy pequeño y la salida z_j , será 1: la neurona se activa.

Por el contrario si x está muy alejado del centroide, r_j será grande y la salida z_j será casi nula.

Una vez calculadas las salidas de la capa oculta, las salidas de la red se calculan de forma lineal:

$$y_k = \sum_j w_{kj} z_j + b_k = \sum_j w_{kj} \Phi(r_j) + b_k \quad (83)$$

Cada neurona de la capa oculta se ocupa de una zona del espacio de entradas. El conjunto de neuronas deberá cubrir totalmente la zona de interés.

1.8.4.3 Regla de aprendizaje de la Redes de Base Radial

Dado que cada neurona radial cubre una parte del espacio de entradas, el número de neuronas de la capa oculta depende de la distribución y de la dimensión del espacio de entradas.

El algoritmo jerárquico auto-organizado, parte de un número reducido de neuronas. Si algún patrón de entrada no activa suficientemente ninguna de las neuronas, se añade otra nueva hasta disminuir un cierto umbral de error.

No obstante, el número de neuronas de la capa oculta suele fijarse por método de prueba y error.

El aprendizaje se puede hacer por un método del gradiente, de forma análoga al algoritmo de retropropagación. Sin embargo, se suele emplear un aprendizaje por etapas: se entrena primero la capa oculta y a continuación la capa de salida.

El entrenamiento de la capa oculta supone determinar:

- Los vectores de peso de las neuronas (centroides)
- Los parámetros de escala σ .

Para determinar los centroides se suele aplicar el algoritmo de las k-medias (k-means) que es un algoritmo no supervisado:

- Elegir los valores de los k centroides de partida. Pueden ser, por ejemplo, los primeros k parámetros de aprendizaje.
- Para cada patrón de entrada, determinar la neurona más cercana y asignársela.
- Recalcular el nuevo centroide de la neurona como promedio de los vectores de entrada que se le han asignado.
- Parar si los cambios en todos los centroides no superan un valor de parada. Volver a 2 en caso contrario.

Puede demostrarse que este algoritmo es equivalente a la regla de aprendizaje competitivo de Kohonen (sin relación de vecindad).

Una vez calculados los vectores de peso, los parámetros de escalas, se calculan por un método heurístico: promedio de las distancias de los patrones asignados al centroide.

Una vez entrenada la capa oculta, la capa de salida (lineal) se entrena usando la regla del asociador lineal. Si es y' la salida de la red e y la salida deseada:

$$w_{kj}(t+1) = w_{kj}(t) + \varepsilon(y_k - y'_k)\Phi(r_j) \quad (84)$$

Este aprendizaje por etapas produce una notable aceleración del tiempo total (por un factor de 3, aproximadamente).

Las RBF se aplican al mismo tipo de tareas que las MLP, con la ventaja de su mayor rapidez de entrenamiento. Pero son mucho más lentas en ejecución debido a que, normalmente, necesitan muchas más neuronas ocultas que los MLP.

Los MLP construyen aproximaciones globales a la correspondencia no lineal entrada-salida y, por consiguiente, pueden hacer buenas generalizaciones a regiones del espacio de entrada donde hay pocos patrones. Por el contrario, las RBF construyen aproximaciones locales y por tanto su capacidad de generalización es pobre.

1.8.4.4 Comparación con el perceptrón multicapa

- La RBF tienen una definición local. El cambio en una de ellas no afecta a la aproximación en otras áreas.

- La cantidad de RBF necesarias para cubrir espacios de dimensiones alta es exponencialmente mayor.
- En el Perceptrón Multicapa (PMC) el cambio de un peso cambia drásticamente toda la función
 - Uso mas eficiente de elementos de proceso
 - El proceso de aprendizaje se relentiza y la adaptación puede caer en un mínimo local.
- Las RBFs aprenden de manera muy eficiente una vez que se han determinado los centros, ya que el error es lineal respecto a los pesos
 - Convergencia al mínimo global
 - Muy útiles para sistemas de identificación
- Las RBFs tienen la propiedad de mejor aproximación según Chebyshev (a diferencia del PMC)

En la actualidad hay muchos tipos de redes neuronales artificiales, y cada año los investigadores crean nuevas arquitecturas, paradigmas y algoritmos de aprendizaje. A fin de tener una visión del panorama actual de las redes neuronales, en el anexo C y D se presentan una síntesis de las Redes Neuronales más conocidas y de las clasificaciones que proporcionan algunos autores, además de algoritmos de aprendizaje más conocidos.

ANEXO L. Tratamiento Digital de la Señal

El término procesado digital de señales se refiere precisamente a la obtención de información a partir de valores muestreados de la señales analógicas. Estas son convertidas en una colección de valores discretos a los que se somete a manipulación algebraica, generalmente en un ordenador, mediante algoritmos que permiten la caracterización de las propias señales o de su interrelación.

Este proyecto usa diversas herramientas para realizar el procesamiento digital de las señales ECG, necesarias en la implementación del electrocardioscopio virtual; por tal motivo es necesario recordar algunos conceptos importantes y la forma de aplicarlos en el software que usa para el procesamiento de los registros electrocardiográficos.

2.1 Análisis de señales basado en la transformada de *Fourier*.

Uno de los métodos matemáticos tradicionalmente con mayor aplicación en el procesado de señales es el basado en las distintas variantes de la transformada de *Fourier* (FT), la cual permite expresar una señal periódica como la suma de infinitas exponenciales complejas. Esto es en muchas ocasiones de gran utilidad, ya que la información contenida en el espectro de

una señal es de vital importancia. Posteriormente a su introducción, se generalizó a señales no periódicas

2.1.1 Análisis de señales continuas en el tiempo.⁹⁷

En esta parte se presentan las herramientas de análisis frecuencial para señales periódicas y aperiódicas continuas en el tiempo

2.1.1.1 Serie de Fourier para señales en tiempo continuo.

Es el resultado de reconstruir señales periódicas con "bloques" elementales (exponenciales complejas), de diferentes tipos mediante la elección de la frecuencia fundamental y de los coeficientes (C_k) que determinan la forma de onda.

Ecuación de síntesis:

$$x(t) = \sum_{k=-\infty}^{\infty} C_k e^{j\omega_k t} \quad (1)$$

Ecuación de análisis:

$$C_k = \frac{1}{T} \int_T x(t) e^{-jk\omega t} dt \quad (2)$$

Hay que garantizar la convergencia de la serie; es decir, garantizar que $x(t)$ y su serie correspondiente sean iguales para todo valor de t .

⁹⁷ Tratamiento Digital de Señales de Proakis y Manolakis. pág. 240-241.

Las siguientes condiciones garantizan lo anterior, excepto en aquellos valores de t en los que $x(t)$ es discontinua:

- La señal $x(t)$ debe tener un número finito de discontinuidades en cualquier periodo.
- La señal $x(t)$ debe tener un número finito de máximos y mínimos.
- La señal $x(t)$ debe ser integrable en cualquier periodo.

Otras formas de representar la serie de Fourier son:

$$x(t) = a_0 + \sum_{k=1}^{\infty} 2C_k \cos(\omega_k t + \theta_k) \quad (3)$$

$$x(t) = a_0 + \sum_{k=1}^{\infty} (a_k \cos 2\pi k F t - b_k \sin 2\pi k F t) \quad (4)$$

Donde:

a_0 componente de continua

$$a_k = 2|c_k \cos \theta_k| \quad (5)$$

$$b_k = 2|c_k \sin \theta_k| \quad (6)$$

2.1.1.2 Transformada de Fourier para señales continuas en el tiempo.

Como se estudió anteriormente si el periodo de una señal se aumenta tanto que tiende a infinito su espectro se vuelve continuo (el espaciado entre líneas espectrales decrece a medida que el periodo aumenta). Por lo tanto, se dice que el espectro de la señal aperiódica es la envolvente del espectro de la señal periódica.

Ecuación de análisis:

$$X(F) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi Ft} dt \quad (7)$$

$X(F)$ es la transformada de Fourier de $x(t)$ y no depende del período de $x(t)$.

Ecuación de síntesis:

$$x(t) = \int_{-\infty}^{\infty} X(F) e^{j2\pi Ft} dt \quad (8)$$

2.1.2 Análisis en tiempo discreto.⁹⁸

Continuando con la misma línea de análisis frecuencial de señales y sistemas, ahora se estudiarán las herramientas de análisis para señales periódicas y aperiódicas discretas en el tiempo.

2.1.2.1 Serie de Fourier para señales discretas en el tiempo.

Debido a que una señal en tiempo discreto tiene un rango de frecuencia limitado, entonces su serie también estará limitada:

$$-\frac{1}{2} < f \leq \frac{1}{2} \quad (9)$$

⁹⁸ Tratamiento Digital de Señales de Proakis y Manolakis pág. 248-249

Ecuación de síntesis:

$$x(n) = \sum_{K=0}^{N-1} C_K e^{j2\pi K n / N} \quad (10)$$

La representación en serie de Fourier de $x(n)$ contiene N exponenciales complejas relacionadas armónicamente.

Ecuación de análisis:

$$C_K = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j2\pi K n / N} \quad (11)$$

C_K es una secuencia periódica de periodo fundamental N:

$$C_{K+N} = C_K \quad (12)$$

Debido a la periodicidad, los coeficientes más allá del rango $K = 0, 1, 2, \dots, N-1$ son idénticos.

En conclusión, el espectro de una señal periódica discreta en el tiempo es periódico, por lo tanto cualquier secuencia de periodo N de la señal o de su espectro proporcionan una descripción completa de la señal, tanto en el dominio del tiempo como de la frecuencia.

2.1.2.2 Transformada de Fourier para señales aperiódicas en tiempo discreto. La transformada de Fourier de una señal de energía finita en tiempo discreto $x(n)$ se define como:

Ecuación de análisis:

$$X(\omega) = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n} \quad (13)$$

Ecuación de síntesis:

$$x(n) = \frac{1}{2\pi} \int_{-\pi}^{\pi} X(\omega)e^{j\omega n} d\omega \quad (14)$$

Los coeficientes de Fourier de la serie $X(\omega)$ son los valores de la secuencia $x(n)$.

2.1.3 La transformada de Fourier discreta “DFT”

El análisis frecuencial de señales discretas en el tiempo se realiza, normalmente, en procesadores de señales digitales. Para realizar este análisis se convierte la señal del dominio del tiempo al dominio de la frecuencia. Como ya se estudió, esto se realiza mediante la transformada de Fourier $X(\omega)$ de la secuencia $x(n)$.

Como el espectro de la señal $x(n)$ es continuo, no se podría hacer un análisis frecuencial de este tipo de señales en un computador. Por lo tanto la DFT es la herramienta computacional que soluciona este problema.

$$X(K) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi Kn/N} \quad K = 0, 1, \dots, N-1 \quad (15)$$

Esta ecuación se denomina **Transformada Discreta de Fourier “DFT”**, ya que las muestras en frecuencia se obtienen de evaluar la transformada de Fourier $X(\omega)$ en un conjunto discreto de N frecuencias.

En la fórmula de la DFT N es el número de muestras que se toman en un periodo de la transformada de Fourier. Por esta razón, al hablar de la DFT se especifica el número de puntos que se tienen en cuenta en el cálculo (por ejemplo, realice la DFT de 10 puntos). Entre más grande sea N mejor es la resolución del espectro obtenido.

Del procedimiento que se presentó anteriormente se deduce que N también determina el período en tiempo discreto de la señal periódica $x_p(n)$ (obtenida del espectro muestreado $X(2\pi K/N)$) y de la cual solo se recuperaba correctamente $x(n)$ si $N \geq L$.

Por lo tanto, el número de puntos con el que se va a realizar la DFT debe ser mayor que el número de muestras de $x(n)$.

Entendido lo anterior, ahora se sabe que el rellenar con ceros no cambia el espectro $X(\omega)$ de la secuencia $x(n)$. Pero al calcular la DFT, rellenar con

ceros proporciona una mejor representación gráfica de la transformada de Fourier $X(\omega)$ ya que se están tomando más muestras de ella.

2.1.4 Análisis Frecuencial de señales usando la DFT

Para calcular el espectro, tanto de señales continuas en el tiempo como de señales discretas en el tiempo, se necesitan los valores de la señal para todos los instantes de tiempo. Sin embargo, en la práctica, solo se obtienen señales durante un periodo de tiempo finito. Por lo tanto, el espectro de la señal debe “aproximarse” a partir de un registro de datos finitos. De esta forma, hay que tener en cuenta dos factores al realizar el análisis frecuencial:

- La distribución de potencia (dispersión o *leakage*).
- La resolución.

2.1.4.1 Distribución de Potencia. Limitar la duración de la señal a L muestras dentro del intervalo $0 \leq n \leq L-1$ es equivalente a multiplicar $x(n)$ por una ventana rectangular $w(n)$ de longitud L :

$$x_v(n) = x(n)w(n) \quad (16)$$

Ya que el espectro de una ventana rectangular (señal con discontinuidades en sus extremos) es una función sinc ($\text{sen}\theta/\theta$), la cual posee grandes lóbulos

laterales, el espectro de la señal de duración finita se distribuirá por todas las frecuencias, fenómeno llamado dispersión o *leakage*.

Cuando se usa la DFT para encontrar el contenido de frecuencia de una señal, se asume que la señal de longitud finita se repite periódicamente en el tiempo. Si no es posible escoger periodos exactos de la señal (como muy seguramente ocurrirá) entonces se presentarán discontinuidades entre periodos sucesivos y como ya se había dicho estas discontinuidades producen dispersión de frecuencias.

Si $x(n) = \cos \omega_0 n$, su espectro solo debería tener componentes en $\omega = \pm \omega_0$, pero debido a que solo se dispone de un número finito de muestras resulta:

$$X_V(\omega) = \frac{1}{2} [W(\omega - \omega_0) + W(\omega + \omega_0)] \quad (17)$$

donde $W(\omega)$ es la transformada de Fourier de la ventana $w(n)$:

$$W(\omega) = \frac{\text{sen}\left(\frac{\omega L}{2}\right)}{\text{sen}\left(\frac{\omega}{2}\right)} e^{-j\omega(L-1)/2} \quad (18)$$




Figura 91. Efecto presentado al ventanear $x(n) = \cos \omega_0 n$

En la gráfica se observa la dispersión o distribución de frecuencias no deseada, con la presencia de lóbulos laterales.

2.1.4.1.1 La importancia del ventaneo

La cantidad de dispersión espectral depende de la amplitud de la discontinuidad. A mayor amplitud de la discontinuidad mayor dispersión y viceversa. Sabiendo esto, es necesario buscar que dichas discontinuidades se hagan mínimas. Se puede usar una “ventana óptima” que reduzca la amplitud de las discontinuidades en los límites de cada periodo. Es decir, multiplicar la secuencia de duración finita por una ventana cuya amplitud varíe “suave y gradualmente” hacia cero en los límites de la señal.

2.1.4.1.2 Algunos tipos de Ventanas.

Estas ventanas óptimas, encargadas de reducir la dispersión de frecuencia pueden ser las siguientes:

- **Hanning:** Esta ventana tiene una forma similar a medio ciclo de una onda coseno. Se define como:

$$w(n) = \begin{cases} \frac{1}{2} \left(1 - \cos \frac{2\pi n}{N} \right) & 0 \leq n \leq N-1 \\ 0 & \text{en el resto} \end{cases} \quad (19)$$

- **Haming:** Esta ventana es una versión modificada de la ventana de Hannig. Se define como:

$$w(n) = \begin{cases} 0.54 - 0.46 \cos \frac{2\pi n}{N} & 0 \leq n \leq N-1 \\ 0 & \text{en el resto} \end{cases} \quad (20)$$

- **Kaiser-Bessel:** Es una ventana flexible cuya forma se puede modificar ajustando el parámetro beta.

Cuando beta está cercano a cero tiene la forma de una ventana rectangular y cuando beta es 5 su forma es similar a la ventana de Hanning.

Esta ventana es buena para detectar 2 señales de casi la misma frecuencia, pero de amplitudes totalmente diferentes.

- **Triangular:** Su forma es triangular. Se define como:

$$w(n) = \begin{cases} 1 - \left| \frac{2n - N}{N} \right| & 0 \leq n \leq N-1 \\ 0 & \text{en el resto} \end{cases} \quad (21)$$

- **Flat-top:** Esta ventana proporciona la mejor aproximación de amplitud de la señal. Se define como:

$$w(n) = \begin{cases} 0.281 - 0.529 \cos\left(\frac{2\pi n}{N}\right) + 0.198 \cos\left(\frac{4\pi n}{N}\right) & 0 \leq n \leq N-1 \\ 0 & \text{en el resto} \end{cases} \quad (22)$$

- **Exponencial:** La forma de la ventana es una exponencial decreciente. Se define como:

$$w(n) = \begin{cases} e^{\left(\frac{n \ln(f)}{N-1}\right)} & 0 \leq n \leq N-1 \\ 0 & \text{en el resto} \end{cases} \quad (23)$$

donde f es el valor final que se desea en la ventana (entre 0 y 1). El valor inicial de la ventana es 1.

2.1.5 La Transformada rápida de Fourier (FFT)

La DFT es una herramienta muy usada en el procesamiento de señales digitales. Una de las razones fundamentales de su importancia radica en la existencia de algoritmos computacionales eficientes, denominados algoritmos para la transformada rápida de Fourier (*FFT, Fast Fourier Transform*) para el cálculo de la DFT cuando el número de muestras es una potencia de 2.

El cálculo de la DFT de una señal de N muestras requiere aproximadamente N^2 operaciones complejas.

Sin embargo, cuando la talla de la señal es una potencia de 2 se puede realizar el cálculo de la DFT con aproximadamente $N \log_2(N)$ operaciones. Esto hace que el cálculo de la DFT sea mucho más rápido.

Las ventajas de la FFT incluyen velocidad y eficiencia de memoria, debido a que por realizar menos cálculos, necesita menos espacios de memoria adicionales para almacenar resultados intermedios durante el procedimiento.

La herramienta (o módulo) que se utiliza en el **electrocardioscopio virtual** para calcular la magnitud del espectro (de la señal ECG), es el que se muestra en la figura 2. Este sub-vi (o sub-módulo) facilita el cálculo de la amplitud del espectro a partir del FFT (en el dominio de la frecuencia). La entrada de este sub-vi es la señal ECG; el tipo de espectro que se desea ver; y el delta de tiempo de muestra a muestra (directamente relacionado con la frecuencia de muestreo); y la salida es: la amplitud del espectro de la señal ECG en el dominio de la frecuencia (ver la figura 2).




Figura 92. Módulo para calcular el espectro de la señal a partir del FFT

2.1.6 Teorema de Parseval ⁹⁹

La potencia media de una señal $x(t)$ periódica es

⁹⁹ SAMIR S. Soliman, MANDYAM D. Srinath. “SEÑALES Y SISTEMAS CONTINUOS Y DISCRETOS”. Editorial Prentice Hall 1999. pág. 135

$$P = \frac{1}{T} \int_{\langle T \rangle} |x(t)|^2 dt \quad (24)$$

La raíz cuadrada de la potencia media, o valor rms (rot-mean-square) de $x(t)$ es una medida útil para la amplitud de señales con formas de onda complicadas. Por ejemplo, la exponencial compleja $x(t) = c_n \exp [jn\omega_0 t]$ cuya frecuencia es $n\omega_0$ tiene una potencia media de $|c_n|^2$. La relación entre la potencia media de una señal periódica y la potencia de sus armónicos es una de las formulaciones (la convencional) del teorema de Parseval.

Hemos visto que si $x(t)$ e $y(t)$ son señales periódicas con el mismo período T y coeficientes de su desarrollo en serie de Fourier β_n y γ_n , respectivamente, el producto de dichas señales tiene un desarrollo en serie de Fourier con los siguientes coeficientes:

$$\alpha_0 = \sum_{m=-\infty}^{\infty} \beta_{n+m} \gamma_m^* \quad (25)$$

observando la Ecuación (26):

$$\sum_{m=-\infty}^{\infty} \beta_{l+m} \gamma_m^* = \frac{1}{T} \int_{\langle T \rangle} x(t) y^*(t) \exp [-jl\omega_0 t] dt \quad (26)$$

La componente continua, o promedio temporal en un ciclo del producto es

$$\begin{aligned}\alpha_0 &= \frac{1}{T} \int_0^T x(t) y^*(t) dt \\ &= \sum_{m=-\infty}^{\infty} \beta_m \gamma_m^*\end{aligned}\quad (27)$$

Si hacemos $y(t) = x(t)$ en esa expresión, entonces $\beta_n = \gamma_n$, y la Ecuación (27) queda

$$\frac{1}{T} \int_0^T |x(t)|^2 dt = \sum_{m=-\infty}^{\infty} |\beta_m|^2 \quad (28)$$

El lado izquierdo es la potencia media de la señal periódica $x(t)$. El resultado indica que la potencia media total de $x(t)$ es la suma de las potencias medias en cada componente armónica. Incluso aunque la potencia es una magnitud no lineal, en esta situación particular podemos aplicar la superposición de las potencias medias, suponiendo que todas las componentes individuales están relacionadas armónicamente.

Tenemos ahora dos formas diferentes de encontrar la potencia media de cualquier señal periódica $x(t)$: en el dominio del tiempo, utilizando el lado izquierdo de la Ecuación (22), y en el dominio de la frecuencia, utilizando el lado derecho de la misma ecuación.

2.1.6.1 Energía de señales no periódicas¹⁰⁰

En la sección anterior relacionamos la potencia media total de una señal periódica con la potencia media de cada una de las componentes en frecuencia de su desarrollo en serie de Fourier, mediante el teorema de Parseval. Nos gustaría encontrar ahora una relación análoga para el caso de señales no periódicas, que sean señales de energía finita. En esta sección demostraremos que la energía de las señales no periódicas se puede calcular utilizando su transformada $X(\omega)$. La energía se define como

$$E = \int_{-\infty}^{\infty} |x(t)|^2 dt = \int_{-\infty}^{\infty} x(t) x^*(t) dt \quad (29)$$

Llamando a esta integral $X(\omega)$ podemos volver a escribir la ecuación :

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega) \exp [j\omega t] d\omega \quad (30)$$

esta ecuación se transforma en

$$E = \int_{-\infty}^{\infty} x(t) \left[\frac{1}{2\pi} \int_{-\infty}^{\infty} X^*(\omega) \exp[-j\omega t] d\omega \right] dt \quad (31)$$

Intercambiando el orden de integración

¹⁰⁰ SAMIR S. Soliman, MANDYAM D. Srinath. "SEÑALES Y SISTEMAS CONTINUOS Y DISCRETOS". Editorial Prentice Hall 1999. pág. 184

$$\begin{aligned}
 E &= \frac{1}{2\pi} \int_{-\infty}^{\infty} X^*(\omega) \left[\int_{-\infty}^{\infty} x(t) \exp[-j\omega t] dt \right] d\omega \\
 &= \frac{1}{2\pi} \int_{-\infty}^{\infty} |X(\omega)|^2 d\omega
 \end{aligned} \tag{32}$$

Por lo tanto, podemos escribir

$$\int_{-\infty}^{\infty} |x(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{\infty} |X(\omega)|^2 d\omega \tag{33}$$

que es la relación de Parseval para señales no periódicas. Indica que la energía de una señal no periódica se puede calcular en el dominio de la frecuencia obteniendo la energía por unidad de frecuencia. $E(\omega) = |X(\omega)|^2 / 2\pi$ e integrando en todas las frecuencias. Por esta razón $E(\omega)$ a menudo se denomina densidad espectral de energía, ya que mide la distribución con la frecuencia de la energía de $x(t)$. Nótese que la densidad espectral de energía de una señal depende del módulo del espectro y no de la fase. Esto implica que existen muchas señales que pueden tener la misma densidad espectral de energía. Sin embargo, dada una señal, su densidad espectral de energía es única. La energía es una banda infinitesimal de frecuencias $d\omega$ es $E(\omega) d\omega$, y la energía contenida en una banda de frecuencias $\omega_1 \leq \omega \leq \omega_2$ es

$$\Delta E = \int_{\omega_1}^{\omega_2} \frac{1}{2\pi} |X(\omega)|^2 d\omega \quad (34)$$

Es decir, $|X(\omega)|^2$ no sólo permite calcular la energía total de $x(t)$ utilizando la relación de Parseval, sino que nos permite calcular también la energía de cualquier banda de frecuencia dada. Para señales reales, $|X(\omega)|^2$ es una función par, y la Ecuación (28) se puede reducir a:

$$E = \frac{1}{\pi} \int_0^{\infty} |X(\omega)|^2 d\omega \quad (35)$$

Las señales periódicas, tienen energía infinita pero potencia media finita. La densidad espectral de potencia es una función que describe la distribución de la potencia media de una señal en función de la frecuencia. A continuación desarrollaremos una expresión para obtener la densidad espectral de potencia de señales de potencia media finita. Sea $x(t)$ una señal de potencia media finita. Definamos $x_{\tau}(t)$ como:

$$x_{\tau}(t) = \begin{cases} x(t) & -\tau < t < \tau \\ 0, & \text{en el resto} \end{cases} \quad (36)$$

$$= x(t) \text{rect}\left(\frac{t}{2\tau}\right)$$

Supondremos también que

$$x_\tau(t) \leftrightarrow X_\tau(\omega) \quad (37)$$

La potencia media de la señal $x(t)$ es

$$P = \lim_{\tau \rightarrow \infty} \left[\frac{1}{2\tau} \int_{-\tau}^{\tau} |x(t)|^2 dt \right] = \lim_{\tau \rightarrow \infty} \left[\frac{1}{2\tau} \int_{-\infty}^{\infty} |x_\tau(t)|^2 dt \right] \quad (38)$$

en donde la última igualdad se desprende de la definición de $x_\tau(t)$. Utilizando la relación de Parseval, podemos escribir la Ecuación (32) de la siguiente forma

$$\begin{aligned} P &= \frac{1}{2\pi} \lim_{\tau \rightarrow \infty} \left[\frac{1}{2\tau} \int_{-\infty}^{\infty} |X_\tau(\omega)|^2 d\omega \right] = \frac{1}{2\pi} \int_{-\infty}^{\infty} \lim_{\tau \rightarrow \infty} \left[\frac{|X_\tau(\omega)|^2}{2\tau} \right] d\omega \\ &= \frac{1}{2\pi} \int_{-\infty}^{\infty} S(\omega) d\omega \end{aligned} \quad (39)$$

donde

$$S(\omega) = \lim_{\tau \rightarrow \infty} \left[\frac{|X_\tau(\omega)|^2}{2\tau} \right] \quad (40)$$

$S(\omega)$ se denomina densidad espectral de potencia de la señal $x(t)$ y representa la distribución o la densidad de la potencia de la señal en función de la frecuencia ω . Análogamente a la densidad espectral de energía, la densidad espectral de potencia depende sólo del módulo del espectro y no de la fase.

La herramienta (o modulo) que se utiliza en el **electrocardioscopio virtual** para calcular la energía de la señal ECG, es el que se muestra en la figura 3. Este sub-vi (o sub-módulo) facilita el cálculo de la energía (señal ECG) en el dominio del tiempo (Teorema de Parseval). La entrada de este sub-vi es la señal ECG y las salidas son: los cálculos de la energía de la señal ECG en el dominio del tiempo y la frecuencia ¹⁰¹.




Figura 93. Módulo para calcular la energía de la señal

2.2 Análisis de Predicción Lineal.

¹⁰¹ Es de anotar que estos dos cálculos van a ser idénticos, ya que la energía de la señal es la misma tanto para el dominio del tiempo como en el dominio de la frecuencia, según el teorema de Parseval por lo tanto se puede tomar cualquiera de los dos resultados.

Una de las técnicas más usadas en el procesamiento de señales de voz viene a ser el análisis de predicción lineal. Esta técnica ha probado ser muy eficiente debido a la posibilidad de parametrizar la señal con un número pequeño de patrones con los cuales es posible reconstruirla adecuadamente. Los parámetros obtenidos mediante este método se caracterizan por variar en forma lenta durante las ventanas de tiempo de análisis.

Otra ventaja es que no requiere demasiado tiempo de procesamiento, lo cual es importante a la hora de la implementación. El análisis de predicción lineal permite aproximar una señal a partir de señales pasadas. En este caso se trata de predecir señales de voz mediante un filtro FIR (filtro de respuesta impulsiva finita), cuya función de transferencia se deduce a partir de:

$$\tilde{s}(n) = - \sum_{k=1}^P a_k \cdot \tilde{s}(n-k) + G \cdot u(n) \quad (41)$$

Como se podrá observar la señal de voz se representa por medio de señales anteriores y $u(n)$ viene a ser la entrada del filtro, el cual será un tren de impulsos periódicos o una fuente de ruido aleatorio. La función de transferencia del filtro se obtiene sacando la transformada z a la relación anterior con lo que se obtiene:

$$H(z) = \frac{G}{1 + \sum_{k=1}^P a_k \cdot z^{-k}} \quad (42)$$

Donde G viene a ser la ganancia del filtro y dependerá de la naturaleza de la señal. Dada la señal $s(n)$, el problema consiste en determinar los coeficientes de predicción a_k y la ganancia G . Serán los coeficientes de predicción los que se usarán como parámetros de reconocimiento de palabras. Su determinación se realiza minimizando el error que se comete cuando se intenta realizar la aproximación de la señal. Sea \tilde{s}_p la señal predicha a partir de la señal s original, entonces:

$$\tilde{s}_p(n) = -\sum_{k=1}^P a_k \cdot \tilde{s}(n-k) \quad (43)$$

El error entre la señal real y la señal predicha será :

$$e(n) = s(n) - \tilde{s}(n) = s(n) + \sum_{k=1}^P a_k \cdot s(n-k) \quad (44)$$

Mediante el método de los mínimos cuadrados, los coeficientes de predicción se calculan minimizando el error cuadrático medio con respecto a cada uno de los coeficientes. Sea el E el error cuadrático total :

$$E = \sum_n e^2(n) = \sum_n \left[\tilde{s}(n) + \sum_{k=1}^P a_k \cdot \tilde{s}(n-k) \right]^2 \quad (45)$$

Se realiza la minimización con respecto a a_k :

$$\sum_{k=1}^p a_k \cdot \sum_n \tilde{s}(n-k) \cdot \tilde{s}(n-1) = - \sum_n \tilde{s}(n) \cdot \tilde{s}(n-i), \quad 1 \leq i \leq p \quad (46)$$

De las dos relaciones anteriores se deducen las ecuaciones:

$$R(i) = \sum_{n=0}^{N-1-i} \tilde{s}(n) \cdot \tilde{s}(n+i), \quad i \geq 0 \quad (47)$$

A continuación se procede a realizar un análisis de autocorrelación. La función de autocorrelación proporciona una medida de la correlación de la señal con una copia desfasada en el tiempo de si misma. Se define como donde p es el orden de análisis. De aquí se extraen los p coeficientes de autocorrelación, valores típicos de p pueden ser entre 10 y 15. Podemos identificar los coeficientes de autocorrelación en las ecuaciones que minimizan los errores en la estimación de la señal predicha. Para resolver esta conjunto de ecuaciones se recurre al algoritmo de Levinson-urbin el cual permite resolver el sistema de ecuaciones de una forma eficiente ver ecuación 48.

2.2.1 Cálculo de los Coeficientes de Predicción Lineal (LPC)

El siguiente paso en el procesamiento es el análisis de LPC, que calcula a partir de cada segmento de autocorrelaciones un vector de coeficientes LPC. El número de coeficientes LPC para representar el segmento de autocorrelaciones es mucho menor que los datos que componen el segmento

de autocorrelaciones aproximadamente la cantidad de información se reduce a $\frac{1}{10}$. Además existen métodos eficientes que comparan un vector de LPC a un segmento de autocorrelaciones para ver que tanto se "parecen". El método formal para convertir los coeficientes de autocorrelación a coeficientes LPC se lleva por nombre "método de Durbin" y se puede escribir como

$$E^{(0)} = R(0) \quad (48)$$

$$k_i = \frac{\{R(i) - \sum_{j=1}^{L-1} \alpha_j^{(i-1)} R(i-j)\}}{E^{(i-1)}}, \quad 1 \leq i \leq p \quad (49)$$

$$\alpha_i^{(i)} = k_i \quad (50)$$

$$\alpha_j^{(i)} = \alpha_j^{(i-1)} - k_i \alpha_{i-j}^{(i-1)} \quad 1 \leq j \leq i-1 \quad (51)$$

$$E^{(i)} = \left(1 - k_i^2 E^{(i-1)}\right) \quad (52)$$

solución final:

$$\alpha_j = \alpha_j^p \quad 1 \leq j \leq p \quad (53)$$

Donde se omite la sumatoria en la segunda ecuación para $i=1$. El conjunto de ecuaciones es resuelto recursivamente para $i = 1, 2, \dots, p$, y la solución final esta dada por $a_m =$ coeficientes LPC $\alpha_m^{(p)}$

La herramienta (o modulo) que se utiliza en el **electrocardioscopio virtual** para calcular los coeficientes de predicción lineal LPC de la señal ECG, es el que se muestra en la figura 4. La entrada de este sub-vi es la señal ECG y las salida son: los primeros 4 coeficientes de predicción lineal de orden 16.




Figura 94. Módulo para calcular los coeficientes LPC de orden 16

Anexo M. Pruebas al sistema

Se realizan todas las pruebas necesarias, tanto para comprobar el buen funcionamiento del software, como para determinar la precisión y exactitud de los resultados.

Las pruebas a realizar consisten en analizar unas ondas patrón de amplitud y frecuencias conocidas y ver como la red neuronal artificial las clasifica; si las reconoce dentro de las arritmias ya identificadas o no; realmente se verifica que tanta eficiencia en su respuesta tiene el sistema ante señales nunca antes vistas.

Estas ondas patrón fueron generadas en LabVIEW (sin que con esto se tenga que emplear un equipo externo al computador) y son las siguientes: onda seno, onda triangular, onda cuadrada, onda sierra, con frecuencias de 1,2,3,4,5 y 6 Hz para cada una de ellas.

Ya que se tiene que hacer el análisis de datos (ondas patrón) provenientes de un archivo, de paso se comprueba el funcionamiento de importar y exportar archivos de Excel. Esto se verifica fácilmente bajo prueba experimental.

1.1 PRUEBA CON LA ONDA PATRÓN SENO

En la siguiente tabla se muestran los resultados obtenidos al tratar de analizar una onda seno de diferentes frecuencias.




Figura 95. Onda Seno patrón de 1Hz.

Tabla 66. Onda Seno patrón a diferentes frecuencias fundamentales y la respectiva identificación que hace la red neuronal

ONDA SENO	
Frecuencia Fundamental	Reconocimiento de la RN
1 Hz	NaN
2 Hz	NaN
3 Hz	TV
4 Hz	SVTA
5 Hz	SVTA
6 Hz	N.

En la tabla 45 se presentan la respuesta que da la red neuronal ante una onda Seno patrón a diferentes frecuencias fundamentales; se ve que ante la onda seno a 1 y 2 Hz, la red no reconoce nada (NaN) pero ante una onda de 3 Hz la red reconoce una Taquicardia Ventricular (VT); a 4 y 5 Hz la red reconoce una Supraventricular taquicardia (SVTA); y finalmente a 6 Hz la red identifica inequívocamente un ritmo cardiaco normal.

Tabla 67. Parámetros temporales y frecuenciales de la onda Seno patrón a diferentes frecuencias fundamentales

Parámetros	1 Hz	2 Hz	3 Hz	4 Hz	5 Hz	6 Hz
Cruces por cero	16	16	16	16	15	16
1-4 Coeficientes LPC	-1,069	-1,091	-2,094	-1,991	-1,985	-1,692
2-4 Coeficientes LPC	0,001	0,008	1,188	1,014	1,012	0,522
3-4 Coeficientes LPC	0,003	0,007	-0,059	-0,024	-0,028	0,143
4-4 Coeficientes LPC	0,002	0,008	-0,065	0,003	0,031	0,041
Frecuencia de Fundamental (Hz)	1	2	2,998	4	5	5,988
Ancho de Banda del 95% energía (Hz)	0	0	0	0	0	0
Desviación Estándar (Frec)	16,322	23,081	28,243	3,264	3,649	3,981
Varianza (Frec)	9,188	11,483	3,399	14,348	7,349	4,228
Energía	1000,01	500,007	333,34	250,004	200,028	166,681
Mediam (mV)	0	0	0	0	0	0
THD	0	0	0,001	0	0	0,003
rms (mV)	0,707	0,707	0,707	0,707	0,707	0,706
Intervalo R-R (seg)	7,999	4	2,67	2	1,6	1,334

La eficiencia de la red neuronal es del 33,33 % pues 4 de 6 resultados son erróneos.




Figura 96. Espectro de la onda Seno a 1 Hz.

1.2 Prueba con la Onda Patrón Triangular




Figura 97. Onda Triangular patrón a 2 Hz.

Tabla 68. Onda Triangular patrón a diferentes frecuencias fundamentales y la respectiva identificación que hace la red neuronal

ONDA TRIANGULAR	
Frecuencia Fundamental	Reconocimiento de la RN
1 Hz	AFIB
2 Hz	T
3 Hz	AFIB
4 Hz	SVTA
5 Hz	AFL
6 Hz	SBR

En la tabla 47 se presentan la respuesta que da la red neuronal ante una onda Triangular patrón a diferentes frecuencias fundamentales; se ve que ante la onda triangular a: 1 y 3 Hz la red identifica una Fibrilación auricular (AFIB); a 2 Hz la red identifica una *Trigeminy Ventricular* (T); a 4 Hz la red reconoce una Supraventricular taquicardia (SVTA); a 5 Hz la red identifica un *flutter* auricular (AFL); y finalmente la onda triangular a 6 Hz la red identifica una Bradicardia sinusal (SBR).

Tabla 69. Parámetros temporales y frecuenciales de la onda Triangular patrón a diferentes frecuencias fundamentales

Parámetros	1 Hz	2 Hz	3 Hz	4 Hz	5 Hz	6 Hz
Cruces por cero	15	16	16	16	16	16
1-4 Coeficientes LPC	-2,668	-1,124	-1,126	-1,146	-1,145	-1,103
2-4 Coeficientes LPC	2,842	0,045	0,041	0,077	0,112	0,132
3-4 Coeficientes LPC	-2	0,013	0,024	0,032	0,035	0,033
4-4 Coeficientes LPC	1,407	0,011	0,018	0,023	0,024	0,022
Frecuencia Fundamental (Hz)	1	2	2,999	4	5	5,988
Ancho de Banda del 95% energía (Hz)	0	0	0	0	0	0
Desviación Estándar (Frec)	10,724	15,165	18,583	21,442	23,94	26,29
Varianza (Frec)	17,117	21,392	6,37	26,73	13,614	8,04
Energía	666,624	333,312	222,529	166,656	133,12	111,664
Mediam (mV)	0	0	0	0	0	0
THD	0,118	0,118	0,118	0,118	0,117	0,117
rms (mV)	0,577	0,577	0,578	0,577	0,577	0,578
Intervalo R-R (seg)	8,001	4	2,668	2	1,6	1,336

La eficiencia de la red neuronal para este caso es del 0,0 % pues 6 de 6 resultados son erróneos.




Figura 98. Espectro de la onda Triangular a 2 Hz.

1.3 Prueba con la Onda Patrón Sierra




Figura 99. Onda Sierra patrón a 3Hz.

Tabla 70. Onda Sierra patrón a diferentes frecuencias fundamentales y la respectiva identificación que hace la red neuronal

ONDA SIERRA

Frecuencia Fundamental	Reconocimiento de la RN
1 Hz	AFIB
2 Hz	T
3 Hz	AFIB
4 Hz	SVTA
5 Hz	SVTA
6 Hz	T

En la tabla 49 se presentan la respuesta que da la red neuronal ante una onda Sierra patrón a diferentes frecuencias fundamentales; se ve que a: 1 y 3 Hz la red identifica una Fibrilación auricular (AFIB); a 2 y 6 Hz la red identifica una *Trigeminy Ventricular* (T); y finalmente a 4 y 5 Hz, la red reconoce *Supraventricular tachyarrhythmia* (SVTA).

Tabla 71. Parámetros temporales y frecuenciales de la onda sierra patrón a diferentes frecuencias fundamentales

Parámetros	1 Hz	2 Hz	3 Hz	4 Hz	5 Hz	6 Hz
Cruces por cero	16	16	15	15	16	15
1-4 Coeficientes LPC	-0,983	-0,964	-0,942	-0,916	-0,887	-0,853
2-4 Coeficientes LPC	0	0,001	0,001	0,003	0,005	0,008
3-4 Coeficientes LPC	0	0,001	0,001	0,003	0,005	0,008
4-4 Coeficientes LPC	0	0,001	0,001	0,003	0,005	0,008
Frecuencia de Resonancia (Hz)	1	2	3,003	4	5	6,006
Ancho de Banda del 95% energía (Hz)	1,031	2,062	3,097	4,125	5,157	6,193
Desviación Estándar (Frec)	6,88	9,728	11,932	13,747	15,389	16,856
Varianza (Frec)	24,892	31,127	9,256	3,889	19,995	11,565
Energía	666,664	333,312	222,218	166,656	133,288	111,1
Mediam (mV)	0,002	0	0,005	0	-0,004	0
THD	0,681	0,681	0,68	0,681	0,684	0,68
rms (mV)	0,577	0,577	0,578	0,577	0,577	0,578
Intervalo R-R (seg)	7,999	4,001	2,664	2	1,6	1,332

La eficiencia de la red neuronal para este caso es del 0,0 % pues 6 de 6 resultados son erróneos.




Figura 100. Espectro de la onda sierra a 3 Hz.

1.4 Prueba con la Onda Patrón Cuadrada

En la figura siguiente se presenta la onda cuadrada a 4 Hz, los resultados obtenidos se observan en la tabla 51 al tratar de identificar la onda cuadrada a diferentes frecuencias.

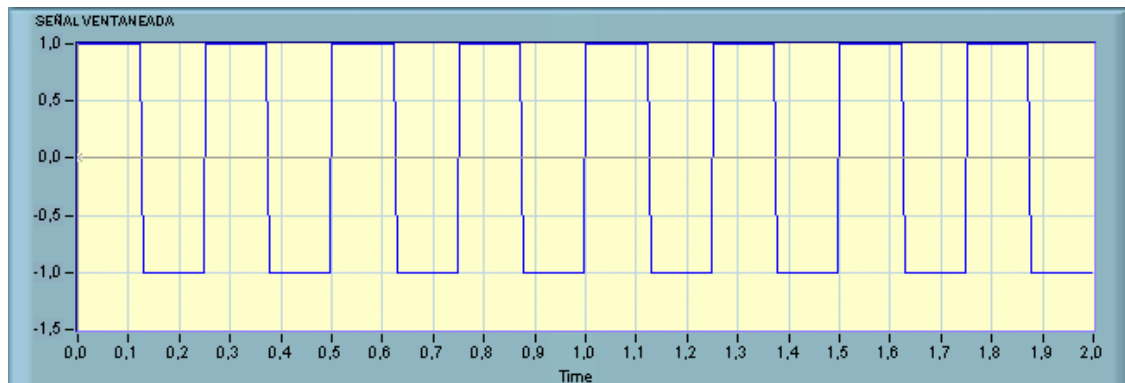


Figura 101. Onda Cuadrada patrón a 4 Hz.

Tabla 72. Onda Cuadrada patrón a diferentes frecuencias fundamentales y la respectiva identificación que hace la red neuronal

ONDA CUADRADA	
Frecuencia Fundamental	Reconocimiento
1 Hz	NaN
2 Hz	NaN
3 Hz	AFIB
4 Hz	T
5 Hz	T
6 Hz	T

En la tabla 51 se presentan la respuesta que da la red neuronal ante una onda cuadrada patrón a diferentes frecuencias fundamentales; se ve que ante la onda cuadrada a 1 y 2 Hz, la red no reconoce nada pero ante una onda de 3 Hz la red reconoce una Fibrilación auricular (AFIB); a 4, 5 y 6 Hz la red reconoce una *Ventricular Trigeminy* (T).

Tabla 73. Parámetros temporales y frecuenciales de la onda cuadrada patrón a diferentes frecuencias fundamentales

Parámetros	1 Hz	2 Hz	3 Hz	4 Hz	5 Hz	6 Hz
Cruces por cero	8	16	16	15	16	15
1-4 Coeficientes LPC	-0,933	-0,949	-0,934	-0,942	-0,877	-0,846
2-4 Coeficientes LPC	-0,055	-0,029	-0,028	0	-0,027	0
3-4 Coeficientes LPC	-0,003	-0,001	-0,001	0	-0,001	0
4-4 Coeficientes LPC	0	0	0	0	0	0
Frecuencia Fundamental (Hz)	1	2	2,999	4	5	6,006
Ancho de Banda del 95% energía (Hz)	0	0	0	0	0	0
Desviación Estándar (Frec)	3,768	3,768	4,613	5,327	5,964	6,524
Varianza (Frec)	7,933	7,933	23,532	9,913	5,1	29,245
Energía	1000	999,951	667	499,976	400	333,057
Mediam (mV)	0	0,996	-1	0,996	0	1,007
THD	0,389	0,389	0,389	0,389	0,392	0,389
rms (mV)	1	1	1	1	1	1
Intervalo R-R (seg)	4	4	2,668	2	1,6	1,332

La eficiencia de la red neuronal es del 33,33% pues 4 de 6 resultados son erróneos.




Figura 102. Espectro de la onda Cuadrada a 4 Hz.

1.5 Reentrenamiento de la Red

Para solucionar los problemas que se presentan con las ondas patrón (seno, triangular, cuadrada y sierra) se procede de la siguiente manera: primero se toman todos los patrones temporales y frecuenciales de las ondas patrón (tablas 46, 48, 50 y 52) y se añaden a la matriz de patrones (matriz P) ya establecida para hacer una nueva clasificación de patrones asignándole un nuevo código (valor 0) a la salida de la red (vector T), que tiene que ser diferente o estar fuera del rango de 1 a 8 al cual se asignó a las arritmias, de acuerdo a la forma como se codificaron los datos presentados a la red neuronal¹⁰².

Al probar el sistema con este nuevo arreglo (descrito anteriormente) se da solución al problema de forma satisfactoria.

¹⁰² Preparación y codificación de los datos numeral 2.2