

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-27

REPRESENTACIÓN DE INFORMACIÓN EN UN SISTEMA DE IMAGINACIÓN MOTORA BASADO EN APRENDIZAJE PROFUNDO

Juan Camilo Ospina Cuervo

Ingeniería de Telecomunicaciones

Director(es):

Andrés Felipe Pérez Zapata
Gloria Mercedes Díaz

INSTITUTO TECNOLÓGICO METROPOLITANO

19 de junio de 2018

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

RESUMEN

El desarrollo de interfaces cerebro computador (BCI) es un campo de investigación que tuvo sus inicios en la década de los 70, pero cuyos mayores avances se han presentado en los últimos años. Entre los diferentes esquemas de BCI, se encuentran aquellos basados en imaginación motora, es decir, los que son controlados por una modulación voluntaria de la actividad cerebral. El desarrollo de estos sistemas se basa en el reconocimiento de patrones de actividad cerebral asociados a la actividad motora, los cuales pueden ser identificados mediante el análisis de señales de electroencefalografía (EEG). Entre las muchas técnicas que se han desarrollado para llevar a cabo este análisis, el uso de técnicas de aprendizaje profundo se ha impuesto recientemente, por su efectividad en la discriminación de la intención motora.

Este documento presenta los resultados de un trabajo desarrollado en el Laboratorio de Máquinas Inteligentes y Reconocimiento de Patrones (MIRP), del Instituto Tecnológico Metropolitano, que busca evaluar los efectos de técnicas de pre procesamiento y de extracción de características en la información que contiene el data set BCI 2IV- 2a, como etapa previa al uso de una arquitectura de aprendizaje profundo, en la clasificación de intención motora a partir de señales de EEG. El trabajo realizado incluye una revisión de la literatura relacionada con los diferentes componentes de un sistema de identificación de imaginación motora a saber: adquisición de señales y selección de electrodos, pre procesamiento, caracterización y clasificación; la implementación de técnicas del estado del arte para el procesamiento y representación de señales de EEG, y la evaluación del efecto de estas en el desempeño de un sistema BCI basado en aprendizaje profundo, implementado en el laboratorio.

Palabras clave: Imaginación Motora, Interfaces Cerebro Computador (BCI), Electroencefalograma, Revisión de Literatura Deep Learnig, Data Set, BCI Competitions, Wavelet, PCA, Red Convolutacional.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

RECONOCIMIENTOS

A la academia por enseñarme a desenvolver mis capacidades intelectuales.

A mi tutora y asesora, la profesora Gloria Díaz por su gran ayuda y colaboración en cada momento de consulta y soporte en este trabajo de investigación.

Al Docente asesor Andrés Felipe Pérez por estar involucrado en la guía durante el desarrollo de este proceso de tesis.

A los compañeros, amigos y co-trabajadores de tesis en las áreas adyacentes del estudio, por la ayuda prestada durante el desenvolvimiento de este trabajo.

A mi familia por ser el soporte más grande.

A Dios y al universo por haber conspirado para mantenerme firme y no decaer a pesar las adversidades presentadas durante este gran esfuerzo y dedicación que comprendió mi carrera como Ingeniero De telecomunicaciones.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

ACRÓNIMOS

MIRP: Máquinas Inteligentes y Reconocimiento de Patrones

ANN: Artificial Neural Network

AR: Autorregresivos

BCI: Brain Computer Interface

CSP: Common Spatial Pattern

CWT: Continuous Wavelet Transform

DFT: Discrete Fourier transform

DWT: Discrete Wavelet Transform

ECG: Electrocardiography

ECoG: Electrocorticogram

EEG: Electroencephalography

EMG: Electromyography

EOG: Electrooculography

ERD: Event Related Desynchronization

ERP: Event Related Potentials

ERS: Event Related Synchronization

FFT: Fast Fourier transform

fMRI: functional Magnetic Resonance Imaging

FT: Fourier Transform

ICA: Independent Component Analysis

k-NN: Nearest Neighbour

LDA: Linear Discriminant Analysis

MEG: Magnetoencephalography

MI: Motor Imaginary

MLP: Multilayered Perceptron

MRI: Magnetic Resonance Imaging

PCA: Principal Component Analysis

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

PET: Positron Emission Tomography

PSD: Power Spectral Density

SVM: Support Vector Machine

WT: Wavelet Transform

RM: Resonancia Magnética

TAC: Tomografía axial computarizada

ECoG: Electrocorticografía

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

TABLA DE CONTENIDO

TABLA DE CONTENIDO	6
1. INTRODUCCIÓN	7
2. MARCO TEÓRICO	10
3. PROCESAMIENTO Y EXTRACCIÓN DE CARÁCTERÍSTICAS PARA EL ANÁLISIS DE SEÑALES DE EEG EN SISTEMAS BCI	29
4. RESULTADOS Y DISCUSIÓN	40
5. CONCLUSIONES, RECOMENDACIONES Y TRABAJO FUTURO	46
REFERENCIAS	48
APÉNDICE	53

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

1. INTRODUCCIÓN

El desarrollo de interfaces cerebro computador (BCI) es un campo de investigación que tuvo sus inicios en la década de los 70, pero cuyos mayores avances se han presentado en los últimos años. Entre los diferentes esquemas de BCI, se encuentran aquellos basados en imaginación motora (MI), es decir, que son controlados por una modulación voluntaria de la actividad cerebral.

Una interfaz cerebro – computador, es un sistema con el cual se puede detectar la actividad neuronal del cerebro de un sujeto o paciente, a partir de la adquisición de diferentes señales que pueden ser medidas y procesadas, para así, reconocer características y patrones de las muestras. En un sistema BCI, comúnmente las muestras estudiadas son de tipo eléctrico provenientes de la actividad del cerebro (Tobergte & Curtis, 2013). Este tipo de herramientas son utilizadas como un puente de comunicación entre una persona y una máquina, ya que al analizar la actividad cerebral, se detectan diferentes estados (grupo de frecuencias) en tiempo real, que pueden ser transformados como datos de salida para posteriormente ser utilizados como órdenes de movimientos.

La actividad cerebral tiene dos tipos de características que son de tipo endógeno y tipo exógeno, las de tipo endógeno son asociadas totalmente a los procesos cognitivos y mentales sin ninguna estimulación, eso quiere decir que son los procesos normales que hace un ser humano cuando piensa o está en reposo, por otro lado están las de tipo exógeno que son generados por agentes externos que los motivan a moverse, pensar o realizar una actividad física (Abaitua, 2012). Estas últimas, son empleadas para el desarrollo de sistemas BCI, que buscan determinar cuál es la acción o pensamiento que está realizando el cerebro.

Un Sistema BCI puede monitorear la actividad cerebral por medio de varias técnicas invasivas y no invasivas (Muñoz Cardona & Eléctrica, 2014), las técnicas invasivas son las que

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

deben hacerse incisiones o mediante inyecciones intradérmicas o subcutáneas, donde se introduce unos electrodos con el objetivo de medir la actividad cerebral mediante estimulaciones eléctricas, esta técnica es conocida como Electrocorticografía (ECoG), las técnicas no invasivas son las más comunes, y entre ellas se destacan algunas pruebas de imagenología como el MEG (Magneto encefalograma), la RM (Resonancia magnética) y el TAC (Tomografía axial computarizada). Este tipo de pruebas, sin embargo, tienen costos muy elevados a diferencia del EEG (Electroencefalograma). Con este último, se pueden tener diferentes conceptos y valoraciones sobre el funcionamiento de las ondas del cerebro a menor costo, por eso la realización de este examen termina siendo más común. Este tipo de sistemas monitorean las diferentes muestras de las cargas electromagnéticas generada por el sujeto o paciente, por medio de electrodos conectados en el cuero cabelludo, en la superficie cortical o en la corteza cerebral (Henríquez Muñoz, 2014).

En particular, un sistema BCI basado en señales de imaginación motora (MI), permite la comunicación entre un usuario y un computador, a través de las señales eléctricas que se generan en el cerebro, al realizarse la tarea de imaginar un movimiento. Un sistema de MI comúnmente se compone de cuatro etapas fundamentales, estas son, primero la adquisición de las señales eléctricas, segundo una etapa de pre procesamiento, tercero extracción de características y finalmente una etapa de clasificación en la cual se interpretan las señales de entrada como ordenes que son enviadas a dispositivos de salida.

El trabajo de laboratorio, cuyos resultados se presentan en este informe, es la implementación de técnicas del estado del arte para el procesamiento y representación de señales de EEG, con el fin de evaluar el efecto de estas en el desempeño del sistema BCI basado en aprendizaje profundo.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Objetivo General

Determinar el efecto de aplicar técnicas de procesamiento de señales para la extracción de información proveniente de EEGs en el desempeño de un sistema BCI basado en una arquitectura de aprendizaje profundo.

Objetivos Específicos

- Revisar el estado del arte sobre técnicas y metodologías de pre-procesamiento y representación de información basadas en Interfaces Cerebro Computador.
- Implementar de técnicas seleccionadas del estado del arte para el pre procesamiento de señales de EEG en un sistema BCI basado en aprendizaje profundo.
- Evaluar las técnicas seleccionadas para la representación de señales de EEG en un sistema BCI

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

2. MARCO TEÓRICO

En los últimos años el estudio del cerebro ha sido un campo del conocimiento en el que científicos, ingenieros y especialistas de diferentes campos han enfocado todos sus esfuerzos, con el objetivo de conocer y elaborar métodos o mecanismos con los cuales se puedan adentrar más en el aprendizaje y conocimiento de cómo funciona el cerebro. Se han encontrado en los últimos años diferentes procesos y teorías, también se han diseñado tecnologías que ha permitido obtener conocimientos de cómo funciona el cerebro humano, aunque estos han sido mínimos, cada día se presentan nuevas investigaciones en este campo (Tobergte & Curtis, 2013).

Las interfaces cerebro-computador (BCI), son una tecnología con la cual se puede adquirir y procesar los diferentes valores obtenidos de señales cerebrales, con el objetivo de reconocer patrones de muestras recolectadas por un dispositivo, como puede ser el Electroencefalógrafo. Con base en estas muestras se puede monitorear las diferentes cargas electromagnéticas, e implementar un sistema BCI que se podría utilizar para generar comunicaciones entre dispositivos externos tecnológicos (computadores, manejo de máquinas o prótesis) y personas, permitiéndoles controlar estos dispositivos (Muñoz Cardona & Eléctrica, 2014).

Para el desarrollo de un sistema BCI, se debe tener una primera etapa donde se seleccione una estrategia con la que se pueda realizar una extracción de información, el método más común para tomar estas muestras es utilizando Motor Imagery (MI), donde un paciente o un voluntario es conectado a un EEG, luego se le empiezan a presentar ciertas imágenes al paciente con el objetivo que imagine cómo realizaría el movimiento o la actividad que se le está mostrando, al realizar este tipo de experimentos se van generando ciertos impulsos eléctricos por parte de la persona que hace la actividad, similares a como si estuviera

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

realizando realmente el movimiento, mientras más práctica tenga la persona con MI, las señales que se generan estarán más asociadas a la intención del movimiento (Henríquez et al, 2014).

2.1 Componentes de un Sistema BCI

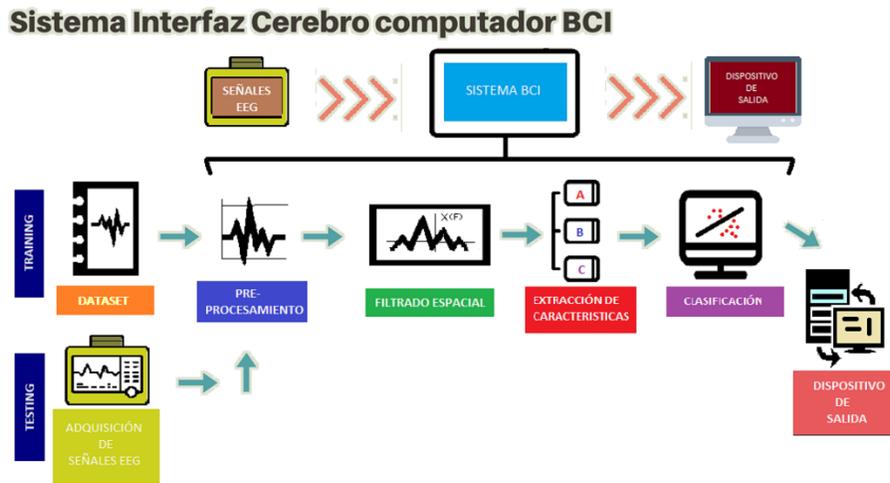


Figura 1 Componentes de un Sistema BCI

La Figura 1, ilustra los componentes fundamentales de un sistema BCI basado en imaginación motora. En general un sistema BCI, al igual que la mayoría de sistemas de aprendizaje computacional, se desarrolla en dos etapas, una primera etapa de entrenamiento (training), en la cual el sistema aprende de muestras de las cuales se conoce la clase o categoría, en este caso el movimiento que es descrito por las señales y una segunda etapa de validación, en la cual el sistema es puesto a prueba para determinar la capacidad de generalización, al determinar el movimiento imaginado a partir de señal que el sistema no había observado antes.

En los dos casos, el sistema está conformado por 6 componentes principales. Una primera etapa de adquisición de las señales, que permite la captura y digitalización de las mismas, en este caso el sujeto es conectado a un EEG, luego se le presentan ciertas imágenes al

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

paciente con el objetivo que imagine cómo realizaría el movimiento o la actividad que se le está mostrando (Abaitua, 2012), generando una cantidad de señales que serán ingresadas al sistema BCI. Una segunda etapa de pre procesamiento, donde las señales son tratadas haciendo uso de filtros de tipo Pasa Altas, Pasa Bajas, Rechaza Bandas o Pasa Bandas, dependiendo de las frecuencias que se necesiten para el desarrollo de la investigación, con este filtrado se trata de eliminar la mayor cantidad de ruido y distorsiones de la señal. Este tipo de filtrados son importantes ya que es normal que las señales contengan frecuencias innecesarias para el sistema. Luego se realiza un Filtrado Espacial, con el objetivo de buscar patrones de comportamiento, estos servirán para una mejor interpretación de los datos, aquí las señales serán transformadas del dominio del tiempo a el dominio de la frecuencia, con esta técnica se podrá filtrar patrones de las señales en diferentes rangos de frecuencia. En el tercer componente, la extracción de características, cada uno de los valores que definen intrínsecamente las distintas frecuencias tomadas del individuo son extraídas al procesar las señales de cada uno de los eventos, tales propiedades son calculadas usando diferentes métodos matemáticos (Ang et al., 2015). Estas representaciones de la información son usadas para clasificar la señal del EEG en una de las categorías de movimiento que se están buscando. En la etapa de entrenamiento, el sistema es entrenado para identificar y reconocer patrones de las actividades del EEG, que permitan asociar las características que describen las señales a clases que representan el movimiento imaginado. Entre mejor sea la calidad de la clasificación del conjunto de datos en la etapa de entrenamiento, mejores serán los resultados para el desarrollo de herramientas en BCI y para ser usadas en los dispositivos de salida (Ang et al., 2011). Una vez el modelo ha sido entrenado, el sistema puede usarse para la clasificación de nuevas señales.

Es importante verificar y hacer comparaciones entre señales reales tomadas de bases de datos donde ya se han realizado los análisis de estas demostrando su calidad y veracidad, para después comparar las señales imaginadas por la persona que ha realizado el experimento para verificar la eficiencia del método (Alonso-Valerdi, Salido-Ruiz, & Ramirez-

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Mendoza, 2015). Es importante resaltar que entre mejores sean los resultados comparativos entre los datos de las dos etapas del Sistema BCI, mejores serán los resultados para la etapa final del proceso que serán vistos en el dispositivo de salida.

2.1.1 Adquisición de las Señales de EEG

El Electroencefalograma (EEG) es una herramienta para el estudio y el registro de las ondas cerebrales, por medio de unos electrodos, puestos sobre la cabeza de los sujetos. Normalmente, se conectan entre 18 Y 40 electrodos en total; que a su vez están conectados a un equipo que tiene la capacidad de registrar corrientes eléctricas. El EEG se basa en las corrientes de naturaleza iónica presentes en la corteza cerebral, que son el producto de la actividad cerebral y pueden ser capturadas con unos electrodos colocados en el exterior del cráneo en diferentes combinaciones, aunque el montaje transversal y el montaje longitudinal a la cabeza del paciente (Megat Syahirul, Aisyah Hartini, Nooritawati, Mohd Nasir, & Faculty of Electrical Engineering, 2014a), son los estandarizados por parte de la Federación Internacional de EEG y Neurofisiología. Previamente, estas corrientes iónicas deben ser convertidas a eléctricas, condición necesaria para que los electrodos metálicos puedan transportar la corriente hasta el amplificador de instrumentación. Según la frecuencia producida por estos impulsos se puede identificar varios tipos de ondas, que pueden ser medidas en cuatro bandas: las bandas delta 0.5 Hz – 4 Hz, theta 4 Hz – 8 Hz, alfa 8 Hz – 13 Hz y beta 13 Hz – 30 Hz, donde cada una de estas frecuencias tiene la información de una tarea específica en los procesos neuropsicológicos de una persona (Abaitua, 2012).

El EEG se encarga de leer el sistema nervioso y a partir de él, realiza el análisis pertinente. El sistema nervioso está compuesto por un conjunto de tejidos que están encargados de captar y procesar de manera rápida las señales internas y externas, tomando control y coordinación sobre los órganos, para así, lograr una interacción oportuna con el medio ambiente. Cuando se produce un estímulo externo, dicho estímulo es recibido en alguna

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

región sensorial ubicados en el cerebro (capturando la información el EEG), la cual es transportada por el sistema nervioso (a través de las neuronas) hasta una componente integradora en donde se analiza. Esta componente elabora una respuesta, que es conducida a través de las neuronas hacia las fibras musculares actividad llamada respuesta motora (Abaitua, 2012).

Existen diferentes tipos de sensores para la captación de las señales: Los electrodos en casco de malla, repartidos a lo largo de un casco elástico. Electrodo de contacto, los cuales son pequeños tubos de plata unidos a soportes de plástico poniendo en el extremo una almohadilla que se humedece con una solución conductora. Electrodo sub-dúral: los cuales se utilizan para registrar la actividad eléctrica directamente desde el cerebro. Los electrodo sub-dúral se implantan en el quirófano bajo anestesia general. Los dos últimos resultan un tanto más incómodos para el paciente. La Figura 2, ilustra un sistema EEG para la toma de muestras de señales



Figura 2 Sistema de EEG, Fuente: <http://uc-cecil.ru>

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

La captación de dichas señales se puede realizar tomando las muestras en el cuero cabelludo o en la base craneal, ya sea con el cerebro expuesto o en localizaciones cerebrales profundas. Sin olvidar la baja relación señal a ruido (SNR), ya que los sensores deben ser alimentados por frecuencias. Esto supondría una señal al menos 1000 veces mayor en amplitud que las medidas del orden de micro voltios (Abaitua, 2012). Este tipo de adquisición de señales con EEG, está enfocado para la elaboración de bases de datos para sistemas BCI, con la ayuda de la imaginación motora (MI), donde las señales de imaginación motora describen la generación de impulsos electromagnéticos, simulando movimientos reales de las extremidades del cuerpo, para generar este tipo de señales los sujetos deben imaginar que están realizando la actividad o el movimiento del cuerpo, sí se desea lograr mejores resultados, se debe tener práctica con la generación de este tipo de impulsos, una de las técnicas que ayudan al método MI, es la visualización de las tareas a imaginar (viendo videos o imágenes) para hacer que las señales sean más robustas, durante la actividad y la recolección de datos para MI, también es útil tener bases de datos que sirvan de referencia para comparar los resultados y así poder llegar a tener una señal útil para BCI (Alonso-Valerdi et al., 2015).

El método más común para tomar muestras de EEG para BCI con MI, es conectar los electrodos al cráneo del sujeto, luego se le presentan ciertas imágenes, con el objetivo que imagine cómo realizaría el movimiento o la actividad que se le está mostrando, similares a cuando realiza realmente el movimiento, esta actividad es llamada imaginación motora (MI), mientras más practica tenga la persona con MI, mejores serán los valores de las muestras (Abaitua, 2012). Es importante verificar y hacer comparaciones entre señales reales tomadas de bases de datos donde ya se han realizado los análisis de estas, demostrando la calidad y veracidad, y compararlas con señales imaginadas por la persona que ha realizado el experimento para verificar la robustez de la captura (Alonso-Valerdi et al., 2015). Con el auge de diseño de aplicaciones de BCI por parte de grandes laboratorios, se ha promovido diferente hardware de bajo costo para la adquisición de muestras con EEG,

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

como son NeuroScan SynAmp, Neurosky MindSet y el Emotiv EPOC. Estas tres herramientas cuentan con especificaciones similares, entre las que se resaltan el hecho de ser portables y de fácil uso, tienen entre 8 y 64 canales para toma de muestras, cuentan con tiempo de autonomía de hasta 12 horas, y recientemente son herramientas muy utilizadas para la experimentación y desarrollo de interfaces cerebro – computador BCI (Muñoz Cardona & Eléctrica, 2014). Las Figura 3 y 4 Ilustran sistemas de EEG para la adquisición de muestras de señales electromagnéticas del cerebro, estos sistemas son hardware bajo costos.



Figura 3 Sistema de EEG Neurosky MindSet, Fuente: <http://www.bgr.in/news/pupillometer-eye-wearable-device-can-spot-diabetes-related-condition/>



Figura 4 Sistema de EE Emotiv G, Fuente: <https://www.thenational.ae/uae/cutting-edge-brain-control-headset-could-cut-uae-s-road-deaths-1.704624>

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

2.1.2 Pre procesamiento

El requisito principal de la etapa de pre procesamiento en BCI es filtrar el ruido producido por artefactos u otras acciones no propias de la actividad de imaginación motora, ya que los sistemas no invasivos de EEG son altamente propensos al ruido, una señal de interés podría estar superpuesta en el tiempo y frecuencia de múltiples señales, que no son parte de las señales producidas por el cerebro o alguna parte del cuerpo, produciendo así interferencias y datos innecesarios para el trabajo que se realiza. Si por el contrario se hace esta etapa de una manera óptima se puede tener así una reducción de datos erróneos y obtenido mayor información relevante para la investigación (Castro, Peluffo, Noguera, & Castro, 2016), (Cho, Ahn, Ahn, Kwon, & Chan, 2017).

Las diferentes técnicas de filtrado frecuencial que se puede implementar en un sistema BCI para extraer información relacionada con las frecuencias del EEG son variadas, en esta etapa se utiliza diferentes tipos de diseños de filtros que abarcan una amplia gama de técnicas que utilizan algoritmos para eliminar de las señales de entrada las frecuencias no deseadas. Los filtros permiten eliminar frecuencias que contaminan y dificultan la interpretación de la señal. Estas deben hacerse procurando no sustraer aquellas frecuencias que forman parte esencial de la actividad eléctrica cerebral. Así, los filtros que más se reportan en la literatura son:

Filtrado Pasa Bajas: permite filtrar las señales con un rango entre los 8 hasta los 12 HZ, este filtro tiene como características que permite el paso de las señales bajas de la frecuencia y bloquea las señales altas en frecuencia (Tobergte & Curtis, 2013).

Filtrado Pasa Altas: filtra señales entre los rangos de 16 hasta los 24 HZ, permitiendo el paso de las señales altas de la frecuencia y bloquea las señales bajas de la frecuencia (Henríquez Muñoz, 2014)

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Filtrado Pasa Bandas: se puede seleccionar una sección del espectro que se desea analizar o una frecuencia de corte donde los valores sean óptimos, este filtro es ideal ya que tiene unas bandas donde pasan los datos y el resto de las frecuencias son atenuadas, dando solo prioridad a un tramo de las frecuencias.

Filtrado Rechaza Bandas: es un filtro que no permite el paso de señales cuyas frecuencias se encuentran comprendidas en las frecuencias de corte superior e inferior, creando así una banda de rechazo y dejando el resto del espectro libre para ser utilizado en la salida de la señal (Kaiser, Kreilinger, Müller-Putz, & Neuper, 2011), este filtro tiene como característica que filtra muy bien el ruido que es generado por señales externas, ya que se pueden eliminar picos en las frecuencias de las muestras tomadas por el EEG (Castro et al., 2016).

Es importante hacer notación que las bandas de interés en las frecuencias pueden cambiar por el sujeto a quien se le toman las muestras, esto puede maximizar el rendimiento del BCI, ya que el pre procesamiento hecho con estos filtros pueden mejorar las señales para que la extracción de características tenga un proceso más eficaz para el desarrollo e implementación del BCI (Henríquez Muñoz, 2014), (Tobergte & Curtis, 2013).

2.1.3 Filtrado Espacial

La etapa de filtrado espacial se puede hacer utilizando diferentes métodos y combinaciones sobre una señal tomada previamente de un EEG. En esta etapa, las señales que fueron filtradas previamente en el pre-procesamiento, donde se eliminaron los ruidos y las distorsiones, son transformadas del dominio del tiempo a el dominio de la frecuencia. Con esta técnica se podrán filtrar patrones de las señales en diferentes rangos de frecuencias, identificando los mejores patrones de comportamiento que puedan ser representados en

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

calidades de los datos de entrada (Kang & Choi, 2014). A continuación, se explicarán métodos que son usados en la etapa de filtrado espacial:

Filtrado ICA (Análisis de Componentes Independientes): es un método que recoge la información de respuesta a un estímulo y separa las señales ruidosas que se generaron dentro del EEG, extrayendo la información relevante, permitiendo la separación de las señales medidas en sus componentes independientes subyacentes fundamentales. Suponiendo que la señal de origen tiene una independencia estadística, los componentes del método no son ortogonales para su separación y únicamente se asume la independencia estadística de las componentes que se generan. Dado un conjunto de observaciones de variables aleatorias, se asume que son generadas por una combinación lineal de componentes independientes o en forma matricial, suponiendo que la matriz creada coincide con la fuente original, permitiendo encontrar una representación lineal de los datos; este tipo de representaciones permite obtener la estructura fundamental de los datos que son necesarios para la extracción de características y la separación de señales. Un punto a favor de ICA es que requiere un mínimo número de canales para funcionar bien, de igual manera, necesita inspección visual para seleccionar sus componentes manualmente para la corrección de datos (Henríquez Muñoz, 2014), (Inuso, La Foresta, Mammone, & Morabito, 2007), (Muñoz Cardona & Eléctrica, 2014).

Filtrado PCA (análisis de componentes principales): intenta encontrar un conjunto de datos en términos de nuevas variables, utilizando matrices de covarianza. Explicando la variabilidad de los datos posibles correlacionados en un número menor de variables no correlacionadas conocido como el componente principal o eje principal, este se calcula con la mayor cantidad de datos obtenidos por las muestras del EEG, los datos restantes de las señales o la segunda varianza más grande es el segundo eje, y así sucesivamente. Por lo cual, una de las ventajas de PCA es dimensionar el grupo de datos, reteniendo las características que contribuyen con mayor varianza, manteniendo un orden de los

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

componentes principales que producen las señales, dejando de lado los componentes de alto nivel y centrándose en los componentes de bajo de nivel, que son los que contiene los aspectos más importantes de la señal. Este método en sí, sintetiza la información o reduce las dimensiones de número de variables. Es decir, ante una señal con muchas variables, el objetivo será reducirlas perdiendo la menor cantidad de información posible (Barachant, Bonnet, Congedo, & Jutten, 2012), (Inuso et al., 2007).

Filtrado CSP (Patrones Espaciales Comunes): este es un método que se utiliza en el filtrado espacial con el cual se extrae características de las señales, esta técnica tiene como particularidad que discrimina datos específicos de las señales de entrada, detectando patrones dentro de las señales del EEG, obteniendo así matrices con varianzas de clases máximas y mínimas al mismo tiempo, estas matrices proporcionan conjunto de patrones espaciales específicos de las señales, que reflejan la activación de las áreas corticales durante el movimiento, obteniendo matrices de la señal de entrada, es decir que el primer componente de los vectores que se crearon, que son las filas, tiene mayor varianza de tipo máximo y las columnas tienen varianzas de tipo mínimo, la interpretación más común es que las filas pueden ser vistas como los filtros espaciales estacionarios, mientras que las columnas pueden ser vistas como los patrones espaciales comunes. CSP no requiere una selección prioritaria de las bandas de frecuencia de las señales que se van a filtrar, pero si se aplica este tipo de filtros a cualquier banda de frecuencia en un rango no especificado, los resultados no serán óptimos, pero si por el contrario se selecciona un rango más estrecho en las bandas de frecuencias da una mejor clasificación de las señales (Reyes, 2013).

Hay que mencionar además que CSP tiene diferentes variaciones, las cuales están siendo utilizadas como técnicas de filtrados espaciales, obteniendo mejoras en su rendimiento. Algunas de estas son RCSP (Regulación de Patrones Espaciales Comunes) (Cheng, Lu, & Wang, 2017), que es un método más robusto que el CSP y menos sensible al ruido, teniendo

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

mayor capacidad para el filtrado de las señales. Aunque su algoritmo es similar al CSP, este agrega dos nuevos parámetros de regularización involucrados en la regulación de las estimaciones de covarianza, uno de estos valores agrega mayor estabilidad en la estimación de las matrices y el otro valor reduce la desviación en las estimaciones, teniendo una mayor precisión que su antecesor y haciendo que el algoritmo tenga una mejor regularización. Otra variación del CSP es el método SBCSP (Sub Bandas de Patrones Espaciales Comunes), es un método más empírico, que utiliza el mismo algoritmo del CSP clásico, la diferencia está en que la señal de entrada que se utiliza en el procesamiento de los datos es descompuesta en pequeñas sub-bandas y es filtrada usando un banco de filtros (Cheng, Lu, & Wang, 2017), así cada sub-banda seleccionada en pequeñas muestras tiene un valor diferente en un rango de frecuencias, por lo tanto la señal es transformada en la sub-banda K-ésima, obteniendo valores más grandes de los resultados de las matrices del algoritmo CSP, es decir la información será más discriminada y tendrá un mayor conjunto de datos con resultados más precisos (Cheng, Lu, & Wang, 2017).

Filtrado Laplaciano: se basa en tomar las señales producidas por los electrodos conectados para la toma de muestras del EEG y es normalizado con cada señal de cada electrodo que rodea el otro, y así sucesivamente se va promediando las potencias de los electrodos vecinos horizontales y verticales, o llamado de otra manera la potencia del electrodo k-ésimo, y dando el promedio de la actividad de referencia de las muestras tomadas (Zhang, Zhou, Jin, Wang, & Cichocki, 2015).

Filtro CAR (Referencia de Media Común): es un método que elimina el ruido de las señales y tiene un costo computacional bajo, hace referencia al promedio de las señales tomadas por los electrodos conectados para la toma del EEG, restando de cada muestra el valor promedio de la señal a través de todos los electrodos. Por lo tanto, el promedio de toda la actividad representa una estimación de la actividad cerebral, donde ese potencial del

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

electrodo k-ésimo muestra el promedio de la actividad de la señal de entrada al sistema (Reyes, 2013), (Zhang et al., 2015)

2.1.4 Extracción de Características

La extracción de características es una técnica que consiste en la realización de distintas combinaciones y transformaciones de las señales de EEG, con el fin de obtener representaciones con características invariables y discriminativas, para conformar un conjunto de datos con la mejor calidad para la etapa de clasificación. La Extracción de Características puede hacerse ya sea en el dominio del tiempo o en el dominio de la frecuencia, las características son cada uno de los valores que definen intrínsecamente los distintos estados del individuo, se explicará a continuación modelos usados frecuentemente en la Extracción de características en sistemas BCI.

Método Autorregresivo (AR): en este método se calcula la densidad espectral de potencia (PSD) de la señal tomada, este describe la potencia en rango de la frecuencia capturada en un proceso estocástico donde se toman magnitudes de los datos que varían en el tiempo, este método divide la señal en bloque de muestras conocidas como ventaneos y luego, en cada ventana se calcula la magnitud utilizando la transformada rápida de Fourier (FFT) (Mohammadpour, Ghorbanian, & Mozaffari, 2016) (Tobergte & Curtis, 2013), estimando la función de auto-correlación de la señal, dando como resultado un valor estimado en forma de PSD, en investigaciones se ha evidenciado que con ventanas más extensas, donde se tiene mayor cantidad de muestras de la señal, se pueden obtener una mejor calidad de los datos, ya que existe mayor capacidad para promediar los datos que están dentro de las ventanas, y así la varianza es más grande, dando una calidad de las muestras de salida unas características más acertadas a las originales (Vaid, Singh, & Kaur, 2015).

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Transformada de Wavelet: es una herramienta matemática que permite analizar señales no estacionarias y de cambios rápidos, A partir de transformaciones y construcciones de la función original, este método realiza una estructura de las señales en dominios del tiempo y la frecuencia por medio de ventanas (Mohammadpour, Ghorbanian, & Mozaffari, 2016), con la combinación de la información frecuencia-tiempo se mejoran la clasificación de las señales dando como resultado mayor precisión, la transformada de wavelet utiliza ambas técnicas teniendo la información contenida en la frecuencia y en el tiempo (Inuso et al., 2007). Una transformada wavelet utiliza una ventana variable en su tamaño lo que le permite realizar mayores mapeos de las señales en esos segmentos donde se requiere mayor precisión en las frecuencias altas o bajas, luego la señal inicia un proceso de separación de datos en porciones de frecuencias, haciendo este proceso en reiteradas ocasiones hasta que se haya descompuesto la señal en tres o más niveles o grupos de señales que están en función de la frecuencia, el tiempo y la amplitud (Bou Assi, Rihana, & Sawan, 2017), luego de este proceso se facilita el procesamiento y la discriminación de la información, dando como resultado la reconstrucción de la señal original. El uso de los coeficientes Wavelet, como características para la clasificación de señales en sistemas BCI ha mostrado buenos resultados, por lo cual es ampliamente usado en la literatura (Inuso et al., 2007).

Dimensión Fractal (DF): en este método la señal será reconstruida por señales más pequeñas de la misma, hasta que se haga una reconstrucción o una reproducción de la original, hay muchas técnicas con las cuales se pueden estimar una dimensión fractal, entre las que se destacan el Método Higuchi y el Método Katz:

Método Higuchi: es una sumatoria de datos que están en función del tiempo, este algoritmo crea nuevas formas de la onda de la señal original en secuencias más pequeñas, creando un vector con muestras que tienen inicio y retardos en tiempos discretos, posterior a este paso se calcula la longitud de la curva de la señal, para obtener los promedios de los datos en

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

factores normalizados de las secuencias, con estos valores se pueden hallar los promedios de todas las longitudes y así convertir la señal en dimensiones fractales y calcular sus aproximaciones lineales en mínimos datos (Nimit Patel et al., 2016).

Método Katz: Encuentra la dimensión fractal, calculando la longitud de la curva de la señal, haciendo la suma de las distancias euclidianas (Las dimensiones euclidianas son todas ortogonales, formando ángulos rectos entre sí y se refieren al espacio físico con las componentes (X, Y y Z), entre varios datos sucesivos, y siendo estos divididos por las distancias más largas de los datos de las muestras, así con este paso se normalizan las tramas de datos y se puede hallar la dimensión fractal de señal de origen. El cálculo de la Dimensión fractal permite determinar las características de las señales del EEG, pero para obtener resultados más acertados se deben utilizar fractogramas más pequeños con los cuales las señales sean reconstruidas mejor (Fraga & Mondragón, 2017), (Loo, Samraj, & Lee, 2011).

2.1.5 Modelos de Clasificación

La Clasificación de un sistema BCI se emplea para identificar y reconocer patrones de las actividades del EEG, identificando la intención del sujeto basándose en las características que tienen los datos que se están recopilando de las señales y las asocia a tareas mentales. Existen dos técnicas de Clasificación que son populares entre las investigaciones de BCI, que son los clasificadores lineales y los clasificadores no lineales (Henríquez Muñoz, 2014). Los Clasificadores Lineales suelen ser más utilizados principalmente por su algoritmo robusto y los pocos parámetros de carga computacional que tienen, ya que los datos son separados linealmente en planos (Hiperplanos) en diferentes regiones (clase) de las señales de entrada, promediando los resultados de la clasificación con el fin de obtener unos datos estadísticamente más acertados. Por otro lado, los clasificadores NO Lineales crean un plano con más dimensiones o zonas arbitrarias con el objetivo hacer regiones (clase) para realizar la separación de datos, tiene como características que deben procesar mayores

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

cantidades de flujos de datos y por lo que su carga computacional es más grande. A continuación, se introducen los modelos de clasificación más usados en sistemas BCI.

Análisis de Discriminante Lineal (LDA): es también conocido con el LDA de Fisher, es uno de los Clasificadores Lineales más usados para BCI, los datos son separados linealmente en planos (Hiperplanos) en diferentes regiones (clase) de las señales, donde sus vectores de características depende exclusivamente de donde quede ubicado en el Hiperplano, LDA asume los datos como matrices de covarianzas (asociaciones lineales de las variables), para crear Hiperplanos de donde se clasifican los datos se deben maximizar las separación de las regiones (clase) de las otras y minimizar las varianzas (evaluar la cantidad de variaciones en los datos debido a factores aleatorios) en las regiones (clase), tiene grandes beneficios ya que es muy fácil de configurar y su carga computaciones es muy baja. El principal inconveniente que tiene el Método LDA es que es un sistema totalmente lineal limitado para proporcionar resultados con datos EEG no lineales (Tobergte & Curtis, 2013).

Máquina de vectores de soporte (SVM): es un clasificador que trabaja de manera similar al método de clasificación LDA. Sus datos son separados linealmente en un plano (Hiperplano) en diferentes regiones (clase) binarias (que solo genera un Hiperplano), con el objetivo de identificar vectores de características en las diferentes regiones, este clasificador define el Hiperplano que maximiza la distancia entre las separación de las regiones (clase), con márgenes más extensas, dando más espacio para evaluar mayor cantidad de variaciones de datos de características proyectándose en un plano dimensional más alto, donde se pueden realizar clasificaciones con mayor carga de entrenamiento de generalización de los datos de entrada del EEG, este método es utilizado con gran éxito ya que su carga computacional es baja (Reyes, 2013).

K-vecinos más Cercanos (K-NN): es un método que utiliza la técnica donde se determinan las distancias entre un punto a clasificar creando un vector en una región de prueba en el

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

espacio de características y un conjunto de datos que sirven para entrenamiento, con las distancias ya medidas se pueden calcular los K-vecinos y con ellos diferenciar las regiones (clase) a las que puede pertenecer y cuáles son las más cercanas, este tipo de distancias son usualmente utilizadas para medir patrones de datos que producirán límites de decisión no lineales, teniendo la probabilidad de que el error en la decisión se reduzca, tomando en cuenta a los K-vecinos en la clasificación. Este método tiene una mayor sensibilidad a la dimensionalidad (Megat Syahirul, Aisyah Hartini, Nooritawati, Mohd Nasir, & Faculty of Electrical Engineering, 2014), que tiene como característica aumentar sus dimensiones del espacio o regiones en forma exponencial, haciendo que los datos se vuelvan dispersos, causando problemas para ser medido el vector de características, pero cuando se utiliza con clasificación de característica con una tasa baja, la dimensión en sus vectores ha demostrado ser eficiente (Henríquez Muñoz, 2014) (Mohammadpour et al., 2016).

Red Neuronal Artificial (ANN): son diseñadas como una similitud a un sistema nervioso, donde se espera que la ANN tenga la capacidad de identificar patrones de entradas de datos y patrones de estados de salida (reales y muestras tomadas), en medio de este proceso la ANN tendrá la capacidad de procesar datos por medio de conexiones de nodos que son denominados capas ocultas, las cuales tienen la capacidad de aprendizaje a partir de un conjunto de patrones de entrenamiento matemáticos, este tipo de procesamiento le permite resolver problemas que no son linealmente separables (Chai, Ling, Hunter, Tran, & Nguyen, 2014), la ANN consta de una capa de entrada, una o varias capas ocultas y una capa de salida, dándole la capacidad de reconocer patrones, ya que tiene la capacidad de aprender de los datos, utilizando un algoritmo de entrenamiento que permite actualizarse hasta que la tasa de errores de la clasificación alcance un estado estable, una vez que la ANN entra en un estado estable, inicia el cálculo de un vector en cada neurona artificial que procesan información por medio de funciones no lineales, como los datos de salida son conocidos por medio de vectores que son ingresados a la ANN (HSU, 2012), la red realiza comparaciones con los datos que clasificó en cada una de sus capas y si tiene errores realiza

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

una nueva etapa de entrenamiento buscando minimizar estos, realizando actualizaciones hasta que la diferencia entre la salida esperada y la real sean los más mínimo posibles y los datos sean óptimos para un sistema BCI (Henríquez Muñoz, 2014) (Turnip & Hong, 2012).

Deep Learning (Aprendizaje Profundo): el aprendizaje profundo tienen las facultades de determinar, automáticamente, la mayor cantidad de características no relacionadas de una amplia cantidad de datos que pudieron ser omitidos en métodos previos al filtrado, gracias a su modelado de abstracciones de alto nivel con transformaciones no lineales. Una de las técnicas de aprendizaje profundo con redes neuronales son las arquitecturas convolucionales (CNN) (Yu & Song, 2017), que consiste en un sistema de múltiples capas de filtros convolucionales de una o varias capas, donde se realiza un mapeo causal no lineal.

Recientemente, las investigaciones sobre clasificación de señales de EEG, están utilizando redes neuronales convolucionales (CNN) para clasificar múltiples clases de señales obtenidas de la Imaginación Motora (MI), acompañado de varios tipos de filtrados como lo son Patrón Espacial Común (CSP), Análisis De Componentes Principales (PCA), Extracción de características con La Transformada Wavelet, entre otros; este tipo de métodos mejora sustancialmente la calidad de los señales para la clasificación, los resultados que se están obteniendo muestran que los CNN pueden aprender características discriminantes para la clasificación de múltiples clases de datos de EEG (Vareka & Mautner, 2017).

Las técnicas de aprendizaje profundo han logrado obtener capacidades notables en el mejoramiento de clasificación de datos ya que con los nuevos dispositivos (hardware) se ha logrado un rendimiento considerable en áreas del conocimiento, como la inteligencia artificial y visión por computador, en estos sistemas se utilizan métodos de análisis comparativos donde se analizan diferentes tipos de arquitecturas de redes neuronales profundas (DNN), utilizando una técnica llamada Pooling para reducir dimensiones, siendo Max-pooling el más utilizado en el estado de la técnica, aunque otras funciones de agrupación pueden mejorar el rendimiento de entrenamiento que es característico en las redes neuronales; también la elección de la función de activación es importante, para que

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

la red neuronal maneje el problema de la disminución del gradiente, esta es una de las claves para una buena limitación del flujo decreciente del gradiente (Mrozik, 2017).

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

3. PROCESAMIENTO Y EXTRACCIÓN DE CARÁCTERÍSTICAS PARA EL ANÁLISIS DE SEÑALES DE EEG EN SISTEMAS BCI

Como se mencionó en la introducción con este trabajo se buscó establecer el efecto del uso de métodos de extracción de procesamiento para la representación de las señales de EEG en un sistema BCI basado en aprendizaje profundo, el cual fue diseñado en el Laboratorio de Máquinas Inteligentes y Reconocimiento de Patrones (MIRP) del Instituto Tecnológico Metropolitano de Medellín. Con base en los resultados de la revisión de trabajos previos, se decidió evaluar dos de los métodos más empleados en la literatura, representación basada en la transformada Wavelet y Análisis de Componentes Principales (PCA). Así mismo, se decidió hacer uso de bases de datos públicas que permitieran comparar los resultados, con los obtenidos en el estado del arte y en el mismo laboratorio MIRP.

En esta sección se describen con mayor profundidad los fundamentos de los dos métodos de representación seleccionados, así como la arquitectura de redes neuronales profundas propuesta. Dado que dicha arquitectura depende de la estructura de los datos de entrada, se describe también la base de datos seleccionada para la evaluación.

3.1 Transformada Wavelet

La Transformada Wavelet, es una herramienta matemática desarrollada a mediados de los años 80 que permite analizar señales no estacionarias. Este método mapea las señales en dominios del tiempo y la frecuencia, utilizando ventanas para observar características de las señales, para los segmentos que es necesario mayor precisión en frecuencias bajas se crean ventaneos con intervalos grandes para la adquisición de los datos en la señal, mientras que para los segmentos que necesiten precisión en altas frecuencias se crean

ventaneos más pequeños, dando resultados óptimos para la interpretación y análisis de los datos (Fabio & Figliola, 2012).

Forma en que opera una Transformada Wavelet:

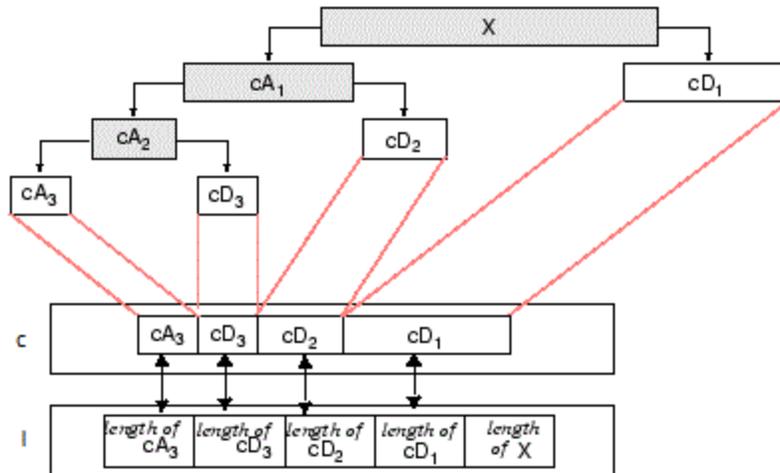


Figura 5 Operación de una Transformada Wavelet, Tomada de Matlab Toolbox

La Figura 5, ilustra el funcionamiento de la Transformada Wavelet, que está compuesta de varias etapas, la señal de entrada en el sistema, es dividida en dos partes con igual cantidad de argumentos, luego una de la señales es filtrada con dos tipos de filtros pasa bajas y pasa altas, teniendo una misma señal en diferentes frecuencias (altas y bajas frecuencias), después una de las señales se le repite el proceso anterior obteniendo un grupo de cuatro señales de la señal original muestreada en diferentes frecuencias o descomposición ortogonal, las subsecuentes divisiones permiten obtener una representación de la señal en *niveles* diferentes de descomposición, lo que también permite reconstruir la señal original ya que se conocen sus frecuencias y sus características, dando la posibilidad de regenerar de una manera más dinámica cada tramo de las señal (Fabio & Figliola, 2012).

La forma como se calcula una transformada wavelet está ligada totalmente a la selección de la Wavelet madre con la que se descompone una señal en diferentes componentes de frecuencia que conforman una familia de funciones que son traslaciones y dilataciones de

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

una función madre $\psi(t)$ (Kouro & Rodrigo, 2002). Este proceso de traslación y dilatación se define en:

$$\psi_{b,a} = \frac{1}{\sqrt{a}} \psi \left[\frac{t-b}{a} \right] \quad (1)$$

- ψ = *Función escalón*
- b = *Parametro de traslación*
- a = *Parametro de dilatación*

Realizando un cambio de variable la Transformada de Wavelet se determina como una integral.

$$F(a, b) = \int_{-\infty}^{\infty} f(x) \psi_{(a,b)}(x) dx \quad (2)$$

- F = *Función Resultante*
- f = *Función de entrada*
- ψ = *Función escalón*
- b = *Parametro de traslación*
- a = *Parametro de dilatación*

Existen un grupo de familias de funciones wavelet, donde cada una de ellas tiene procesos y tipos de ventaneos diferentes, entre ellas se destacan: Haar, daubechies, Biortogonal, coifetes y symlet, entre otras.

Las características de este grupo de familias son:

- Soporte compacto: Útil para procesamiento de señales finitas en la práctica, ventaja sobre el análisis de Fourier.
- Regularidad: Útil para detección de singularidades en contornos en 2 dimensiones.
- Ortogonalidad: Útil para compresión de señales e imágenes

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

- Simetría de la función de escala: Sería útil para tratamiento de funciones simétricas y en imágenes.

La transformada continua de Wavelet (CWT): Es una implementación de la transformación wavelet utilizando escalas arbitrarias, las wavelets utilizadas no son ortogonales y los datos obtenidos por esta transformada están altamente correlacionados. Para las series de tiempo discretas también se utilizan este tipo de transformación, con la limitación de que las traducciones de ondas más pequeñas deben ser iguales al muestreo de datos. Esto a veces se denomina Transformada Wavelet Continua en Tiempos Discretos (DT-CWT) y es la forma más utilizada de calcular CWT en aplicaciones reales, otra forma de entender la transformada wavelet continua es comprender que se utiliza la convolución de la señal con la wavelet escalón. El algoritmo utilizado para este cálculo se puede basar en una convolución directa por medio de la multiplicación en el espacio de Fourier (Fabio & Figliola, 2012)

$$Wf(a, b) = \sqrt{|a|} \int_{\mathbb{R}} f(au + b)\psi(u)du \quad (3)$$

- Wf = *Función Wavelet*
- b = *Parametro de traslación*
- a = *Parametro de dilatación*
- u = *Dominio frecuencial*

La transformada wavelet discreta (DWT): es una implementación de la transformada wavelet utilizando un conjunto discreto de escalas wavelet, esta transformada descompone la señal en un conjunto mutuamente ortogonal de wavelets, que es la diferencia principal de la transformada wavelet continua (CWT), o su implementación para la serie temporal discreta a veces llamada transformada wavelet continua discreta (DT-CWT)(Fabio & Figliola, 2012).

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

La wavelet se puede construir a partir de una función de escala que describe sus propiedades de escala.

$$\psi(x) = \sum_{k=-\infty}^{\infty} a\kappa\psi(Sx - \kappa) \quad (4)$$

- ψ = *Función escalón*
- k = *Parametro de números enteros*
- a = *Parametro de dilatación*

Donde ψ es un factor de escala y debe ser ortogonal

$$C_{j,k} \int_{\mathbb{R}} f(x)\psi(2^j x + k)2^{j/2} dx \quad (5)$$

- $C_{j,k}$ = *Cantidad discreta de coeficientes wavelet*
- f = *Función de entrada*
- ψ = *Función escalón*
- k = *Parametro de números enteros*
- $a = 2^j$ = *Parametro de dilatación*

Análisis De Componentes Principales (PCA)

Es una técnica de la estadística que sintetiza la información, reduciendo las dimensiones de los datos de entrada de una señal, esto quiere decir que un data set con muchas variables al ser filtrado con PCA, obtendrá un menor número de variables perdiendo la menor cantidad de información posible (Figueroa, Carrera, & Jim, 2012).

Los nuevos componentes principales o factores serán una combinación lineal de las variables originales, y además serán independientes entre sí. Un aspecto relevante en PCA es la interpretación de los factores, ya que éstos serán interpretados tras observar la

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

relación de los factores con las variables iniciales buscando entre ellos los factores de correlación existentes entre ellos (Barachant et al., 2012).

Se considera una serie de variables (x_1, x_2, \dots, x_n) sobre un grupo de objetos o individuos y se trata de calcular, a partir de ellas, un nuevo conjunto de variables (y_1, y_2, \dots, y_n) , sin correlación entre sí, cuyas varianzas vayan decreciendo progresivamente. Cada y_j (donde $y = 1, \dots, p$) es una combinación lineal de las (x_1, x_2, \dots, x_n) originales, es decir:

$$y_j = a_{j1}x_1 + a_{j2}x_2 + \dots + a_{jp}x_p = a'_j x \quad (6)$$

Siendo $a'_j = (a_{1j}, a_{2j}, \dots, a_{pj})$ un vector de constantes, y

$$x = \begin{bmatrix} x_1 \\ \cdot \\ \cdot \\ \cdot \\ x_p \end{bmatrix} \quad (7)$$

Obviamente, si se desea es maximizar la varianza, una forma simple podría ser aumentar los coeficientes a_{1j} , con el objetivo de mantener la ortogonalidad de la transformación se impone que el módulo del vector $a'_j = (a_{1j}, a_{2j}, \dots, a_{pj})$

Es decir,

$$a'_j a_j = \sum_{k=1}^p a_{kj}^2 = 1 \quad (8)$$

El primer componente se calcula eligiendo a_1 de modo que y_1 tenga la mayor varianza posible, sujeta a la restricción de que $a'_1 a_1 = 1$. El segundo componente principal se calcula obteniendo a_2 de modo que la variable obtenida, y_2 esté sin correlación con y_1 .

Los análisis que se deben tener en cuenta cuando se decide realizar un filtro PCA, está determinado por estas características:

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Análisis correlaciones: un análisis de componentes principales tiene utilidad en una señal de EEG si existen altas correlaciones entre las variables de las señales, ya que esto quiere decir que existe información redundante en los datos, si no existiera factores que denotan algún intercambio mutuo entre la trama de datos se entenderá que existe que la señal no tiene una gran variabilidad en sus cualidades y no se obtendrá una correlación apta para este tipo de filtrado (Inuso et al., 2007).

Cálculo de las covarianzas y correlaciones entre las variables originales y los factores.

$$Cov(y_j, x_i) = Cov(y_j, \sum_{k=1}^p a_{ik} y_k) = a_{ij} Var(y_j) = \lambda_j a_{ij} \quad (9)$$

Con lo que la matriz factorial también mide las correlaciones entre las variables originales estandarizadas y los nuevos factores.

Selección de factores: Los factores realizan una tarea de verificación de variabilidad de tal forma que el primero recoge la mayor proporción posible de la variabilidad original, el segundo factor debe recoger la máxima variabilidad posible no recogida por el primero, y así sucesivamente, donde al final del total de factores se elegirán aquéllos que recojan la mayor cantidad del porcentaje de variabilidad que se considere suficiente a éstos se les denominará componentes principales.

Matriz factorial: Una vez seleccionados los componentes principales, estos serán recogidos en una matriz, donde cada elemento de ésta representa los coeficientes factoriales de las variables, las correlaciones entre las variables y los componentes principales, la matriz tendrá igual cantidad de columnas de componentes principales y filas de variables (Barachant et al., 2012).

$$a_j^* = \lambda_j^{1/2} a_j \quad (10)$$

Para $j = 1, \dots, p$

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Otra manera de ver la matriz factorial es:

$$Conv(x) = (A^{-1})' Conv(y) A^{-1} = A \Lambda A' = A \Lambda^{1/2} \Lambda^{1/2} A' = FF' \quad (11)$$

Ya que A al ser ortogonal, resulta que $A^{-1} = A'$, Así, dada la matriz factorial F , se pueden calcular las covarianzas de las variables originales, es decir, se puede recuperar la matriz de covarianzas original a partir de la matriz factorial (Barachant et al., 2012). Si se toma un número menor de factores ($m < p$), se podrá reproducir aproximadamente Σ .

3.3 Bases de datos para experimentación

Las competencias de BCI, han sido en los últimos años herramientas que han servido en investigaciones y trabajos relacionadas, estas competencias han tenido gran acogida por parte de grupos de investigación, ya que los conceptos y desarrollos han brindado algoritmos óptimos y robustos con los cuales se han podido realizar aproximaciones a la comprensión de los datos que pueden ser arrojados por un EEG sobre el comportamiento de la funcionalidad del cerebro, basándose en la adquisición de señales tomadas de la corteza cerebral (Tangemann et al. 2012). Uno de los valores agregados más importantes que tienen las competencias BCI, son las características de sus datos, ya que estos tienen una disponibilidad libre para su uso, de igual manera promueven la cooperación interdisciplinaria, donde investigadores, científicos de la neurociencia, analistas de datos, entre otros, realizan diseños de algoritmos y técnicas para la extracción y clasificación de datos para el procesamiento de señal y el aprendizaje automático (Andrés F. Pérez, Andrés F. Cardona, Jorge A. Jaramillo, & Gloria M. Díaz, 2018).

Los datos que han sido adquiridos en la competencia 2a, tiene como características que fueron tomados en un grupo de 9 sujetos, utilizando un EEG, por medio de 6 sesiones con un total de 288 pruebas por sujeto utilizando imaginación motora (MI), por cada uno de las 4 clases que tiene este conjunto de datos (Clase 1 mano izquierda, Clase 2 mano derecha,

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Clase 3 Ambos pies y la Clase 4 la lengua). Las señales de EEG que conforman este conjunto de datos, fueron muestreadas a 250 Hz y se les aplicó un filtro pasa banda entre el rango de frecuencias de 0.5 a 100 Hz, además de un filtro rechaza banda (notch filter) a una frecuencia de 50 Hz, con el objetivo de minimizar el ruido que pueda tener la señal. Una característica que tiene esta base de datos es que, al tener 4 tipos de clases, contiene el riesgo de una reducción en la precisión en la clasificación (Clemens Brunner, Robert Leeb, Gernot Müller-Putz, Alois Schlögl, 2008). Sin embargo, también ofrece mayores velocidades de transferencia de información, y una interacción más natural entre el usuario y el sistema BCI los datos en un principio están en formato GDF con una cantidad de 672528 x 25 datos en una matriz donde combina datos de EEG y EOG, pero como los datos relevantes para la tarea de filtrado que se deseaba realizar eran los de datos EEG se utilizaron los datos tomados de los primeros 22 canales de las señales.

Modelo basado en aprendizaje profundo

El modelo de aprendizaje profundo, empleado en este trabajo, corresponde a una red neuronal convolucional (CNN) compuesta de 9 capas convolucionales, que son las responsables de extraer las características necesarias de las señales pre-procesadas, las capas están compuestas por núcleos de 3x3, donde las características de los mapas se calculan en cada capa, de igual manera se da un sub muestreo MaxPooling aplicado en regiones 2x2 para preservar solo la información más relevante. Cada capa convolucional es iniciada por el kernel uniforme Glorot. Además, tiene incluido un perceptrón multicapa (MLP) con el objetivo de recibir la información de la última capa convolucional para Imaginación Motora (MI), también es importante entender que la primera capa densa está compuesta por 2048 neuronas y la última capa usa 1024 unidades, finalmente la red es alimentada con una función softmax la cual es la capa de salida de la red neuronal, que contiene una neurona correspondiente a cada tipo de clase del data set (Pérez et al., 2018). Esta arquitectura, fue implementada usando Keras sobre Tensorflow, ya que son herramientas potentes para el desarrollo de estos sistemas, los experimentos se llevaron a

cabo en la distribución de Kubuntu Linux, en una Dell Precisión con CPU T5810, equipada con procesadores Intel Xeon de 3 GHz, 8 núcleos, arquitectura de 64 bits, 16 GB de RAM también se utilizó GPU NVIDIA GFORCE 1080 TI en este trabajo.

Para la evaluación de las bases de datos, la red debe entrenarse 50 épocas por cada sujeto que es ingresado al sistema, obteniendo resultado por cada uno de ellos. Las imágenes que ingresan en la CNN usan un minibatch de tamaño 10. De igual forma el método propuesto realiza validación cruzada de 5 particiones, dejando el 80% del conjunto de datos para el entrenamiento y un 20% restante para la validación.

Las Figuras 6 y 7, ilustran la arquitectura de que fue implementada en este trabajo, acompañada de los tipos de filtrados utilizadas en el desarrollo.

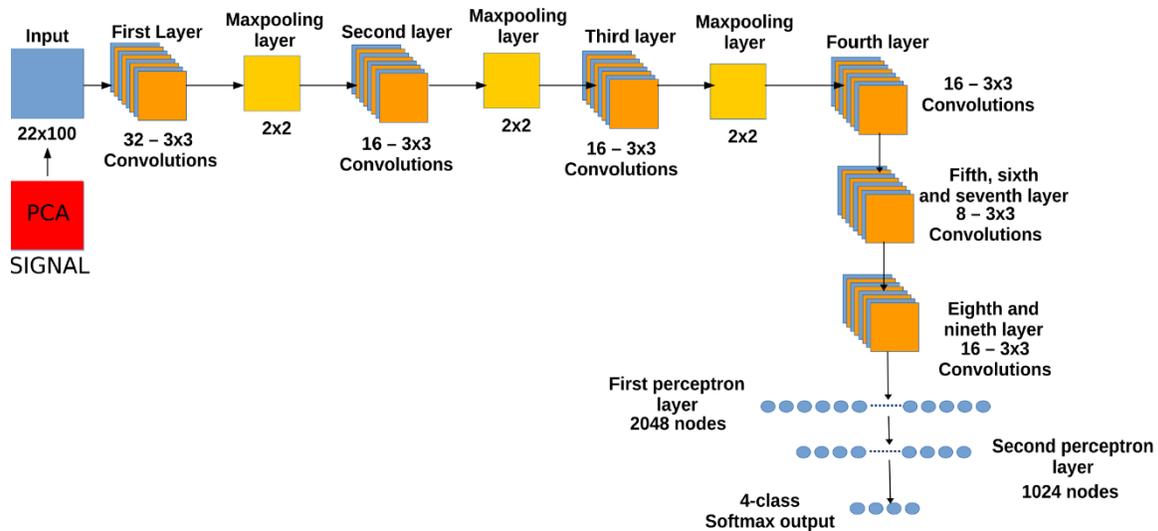


Figura 6 Arquitectura Red Convolutacional Con Filtro PCA, (Andrés F. Pérez, Andrés F. Cardona, Jorge A. Jaramillo, & Gloria M. Díaz, 2018).

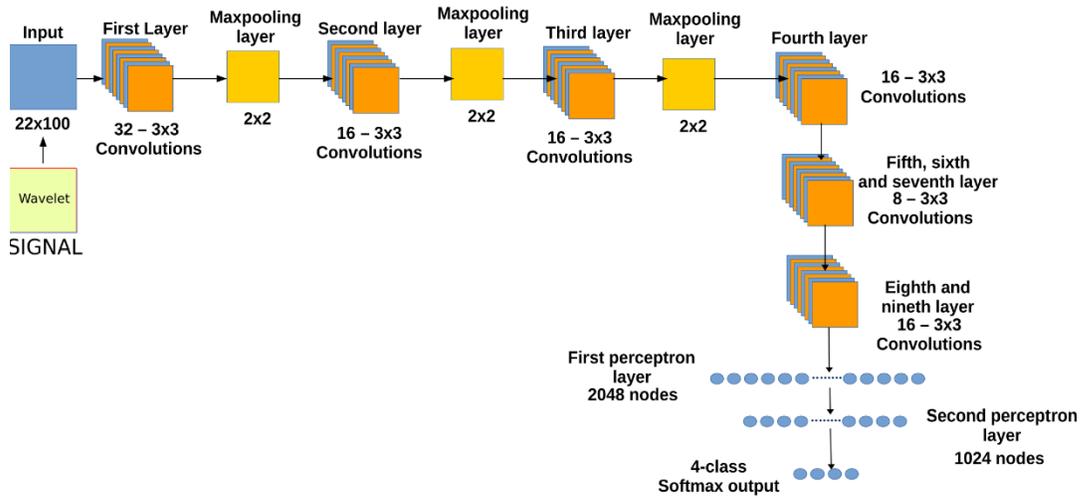


Figura 7 Arquitectura Red Convocional Con Wavelet, (Andrés F. Pérez, Andrés F. Cardona, Jorge A. Jaramillo, & Gloria M. Díaz, 2018).

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

4. RESULTADOS Y DISCUSIÓN

A continuación, se describen los resultados obtenidos en la clasificación de las señales de Imaginación Motora que componen en conjunto de datos de la competencia BCI IV- 2a, descrito en el capítulo anterior.

4.1. Configuración de parámetros experimentales.

4.1.1. Representación basada en wavelets

El primer experimento consistió en evaluar diferentes funciones madre y diferentes niveles de descomposición para la implementación basada en la transformada Wavelet. Teniendo en cuenta que una experimentación exhaustiva requeriría un costo computacional y de tiempo importante, se evaluaron las funciones madre y niveles de descomposición que presentaron mejores resultados en un trabajo reciente que buscaba evaluar el desempeño de la representación Wavelets en un sistema BCI (Alansari, Kamel, Hakim, & Kadah, 2018) como se describe en la Tabla 1. Este trabajo, sin embargo, presenta esta evaluación usando dos tipos de clasificador Logistic Regression (Regresión Logística) y SVM (Maquinas De Vectores De Soporte), y los resultados se refieren a la base de datos BCI IV- 2b, la cual tiene como características que el conjunto de datos que fueron recopilados fueron tomados de un grupo de 9 personas que realizaron 5 sesiones diferentes utilizando la imaginación motora (MI), estas se dividieron en 2 sesiones de entrenamiento sin feedback (retroalimentación) y 3 sesiones con feedback, por cada uno de las 2 clases que tiene este data set (Clase 1: mano izquierda, Clase 2: mano derecha), teniendo como herramienta para recolectar los datos un EEG de tres canales C3, C4 y Cz, con una frecuencia de muestreo de 250 Hz (Brunner & Leeb, 2008).

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

Tipo de Wavelet	Nivel Wavelet
Wavelet Colf5	2
Wavelet Bior1,5	3
Wavelet db1	4
Wavelet db2	5
Wavelet Sym1	7

Tabla 1 Wavelets Madre y niveles de descomposición usados por Alansari et al. (2018)

Para la implementación de estos algoritmos, se emplearon las funciones provistas por Matlab, en el Wavelet ToolBox, el cual proporciona funciones y aplicaciones para analizar señales en función del tiempo y la frecuencia siendo útil para eliminar ruido de las señales o comprimir los datos mientras conserva sus características principales.

4.1.2 Representación basada en PCA

Para la representación basada en PCA se evaluó el efecto que tiene el diseño del filtro en la base datos BCI IV-2a, donde, para cada muestra de cada sujeto se implementó la función “[**COEFF,SCORE,LATENT**] = **pca (data(:,:),'Algorithm','svd')**”, la señal de entrada está compuesta por un grupo de datos de 90432 x 22, un argumento '**Algorithm','svd'** que selecciona los valores singulares de los datos que son ingresados en el filtro PCA, para el análisis de los componentes principales se seleccionó el valor de salida de la variable **SCORE**, ya que al realizarse el filtro no se contaba con el tiempo necesario para desarrollar un algoritmos que analizara los 22 canales con los que contaba los 9 sujeto del data set, lo más común en este tipo de diseño es que se analicen los datos en pequeños tramos de la señal para poder evidenciar de mejor manera los coeficientes con unas dimensiones “X” y que sean convertida en pequeñas tramas de señal con una dimensionalidad reducida donde se representen un conjunto de datos variables y lineales llamados componentes principales, la variable **SCORE** realizo un análisis completo de los 22 canales y todos los datos que se produjeron en los experimentos que realizo cada uno de los sujetos en la toma de muestras, fueron ingresados a la función sin ser separados, donde la evaluación del filtro PCA arrojo

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

valores en una nueva matriz con 89251 x 22 datos, este filtrado determino un grupo de variables no correlacionadas en un nuevo conjunto de datos, sintetizando la información y las dimensiones de la matriz de entrada. Es decir, ante una señal con muchas variables, el objetivo fue reducirlas perdiendo la menor cantidad de información posible.

4.2. Resultados

La tabla 2, presenta los resultados obtenidos con cada una de las configuraciones de los experimentos implementados, para cada sujeto de la base de datos, y el promedio general. Se incluyen los resultados obtenidos, con la arquitectura de aprendizaje profundo sin realizar ningún procesamiento de los datos (Andrés F. Pérez et al., 2018), los obtenidos para las 6 configuraciones de representación basada en Wavelets y los obtenidos con PCA.

BCI IV- 2a Accuracy								
Sujeto	Wavelet db1 Nivel 1	Wavelet Colf5 Nivel 2	Wavelet Bior1,5 Nivel 3	Wavelet db1 Nivel 4	Wavelet db2 Nivel 5	Wavelet Sym1 Nivel 7	PCA	Red Sin Filtros
S1	0,75	0,68	0,67	0,67	0,53	0,78	0,88	0,86
S2	0,73	0,88	0,53	0,89	0,84	0,62	0,94	0,87
S3	0,72	0,85	0,94	0,73	0,68	0,72	0,83	0,93
S4	0,70	0,85	0,90	0,82	0,70	0,72	0,86	0,85
S5	0,83	0,73	0,85	0,74	0,59	0,67	1,00	0,84
S6	0,83	0,73	0,94	0,84	0,76	0,80	0,51	0,86
S7	0,88	0,83	0,76	0,67	0,56	0,79	0,99	0,88
S8	0,89	0,66	0,68	0,68	0,68	0,60	0,80	0,89
S9	0,92	0,73	0,51	0,69	0,50	0,84	0,99	0,92
Average	0,81	0,77	0,75	0,75	0,65	0,73	0,87	0,88
STD	0,08	0,08	0,17	0,08	0,11	0,08	0,15	0,03

Tabla 2 Exactitud de la clasificación de señales de EEG en un sistema BCI, empleando diferentes métodos de representación, para la base de datos BCI Competition IV 2a

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

De acuerdo con los resultados, presentados en la Tabla 2, de los experimentos implementados se observa que la aplicación de filtros Wavelets y PCA reduce el desempeño del sistema BCI basado en redes neuronales profundas. En particular, las Transformada Wavelet db2 Nivel 5, ya que sus resultados en la clasificación son menores al grupo de otras transformadas, con un 65% de efectividad, del grupo de resultados cruzados con la referencia que es la red sin filtro, tiene un margen de diferencia de 26.24% menos. Un dato importante sería verificar los niveles de descomposición que puede tener una wavelet ya que estos varían drásticamente los valores en las clasificación, haciendo este análisis ya que la wavelet madre db1 nivel 1 tenía un nivel menor al db2 y obtuvo mejores resultados en su clasificación, realizando una observación mejor de estos datos se podrá mejorar el experimento de la transformada.

También se analiza que los experimentos con las transformadas wavelet ofrecen resultados de desviación estándar más elevados con el valor de referencia que ofrece el sistema de evaluación profunda, donde sus valores están en un 0.3% de desviación, en comparación con los de transformada wavelet, donde sus valores de clasificación por sujeto están muy dispersos en cada uno de sus resultados y cuando se realiza la desviación estándar se producen resultados mayores, dando un rendimiento de 0.8 hasta 0.17, estos resultados indican que el grado de confiabilidad en la clasificación es bajo.

Por el contrario, el filtro PCA genera un desempeño cercano a los resultados que tiene la red convolucional (CNN), a pesar de que no se realizó un algoritmos que analizara los 22 canales con los que contaba los 9 sujeto del data set, y donde se analizó la variable **SCORE** quien arrojo datos de análisis completos de los 22 canales y todos los datos que se produjeron en los experimentos que se realizó en cada uno de los sujetos, evidenciando unos resultados similares a los que tiene el valor con el que se referencia los datos (Red sin filtro), sin embargo es muy evidente observar que tiene una desviación estándar mayor a la que se esperaba, pero esto se debe a que varios de los datos que se obtuvieron por los sujetos están muy dispersos, así que esto afecta realmente a la confiabilidad del sistema, si se pudiera realizar mayores verificaciones de la función y análisis de como es el diseño de

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

esta, un dato importante sería verificar como se calcula el **SCORE**, ya que el tamaño de las matrices que retorna son valores tomados del promedio de las señales de entrada, así sería mucho sencillo verificar si los datos que retorna son basados en los coeficientes que debe entregar la función PCA.

4.3. Discusión

Se analizaron metodologías que incluyen diferentes tipos de filtrado espacial y extracción de características, utilizando un clasificador basado en redes convolucionales profundas. De acuerdo a los resultados presentados en la Tabla 2., se logra evidenciar.

Al realizar el análisis de los resultados por cada una de las transformadas wavelets madre que se implementaron para el desarrollo de trabajo, se puede identificar que el diseño del algoritmo con cada una de sus diferencias requieren un mayor análisis para su implementación, ya que se puede evidenciar que el valor de los niveles de descomposición determina de una manera significativa los resultados, se creyó que al realizar una comparación con los datos encontrados en el artículo de referencia (Alansari, Kamel, Hakim, & Kadah, 2018) se obtendría unos resultados mejores, pero se determinó que es más valiosos realizar un análisis profundo de cómo trabaja mejor el filtro, con sus características y como se podría mejorar el sistema BCI

De igual forma se pudo demostrar, que el **Filtrado PCA (análisis de componentes principales)**, es una técnica que arrojo buenos resultados y pese a que su implementación no se realizó por cada uno de los componentes que conforma el conjunto de datos de cada sujeto del data set, se obtuvieron resultados mejores a los de la transformada wavelet, pero no iguales o mejores a los valores de referencia, no obstante tiene valores que demuestran una efectiva de la función PCA para los sistemas BCI, dando una aceptación en el rendimiento del método se ha evaluado mediante experimentos utilizando datos reales.

En general, los resultados obtenidos para los datos de la competencia BCI IV – 2a, revelan una precisión de clasificación de los 8 algoritmos que se muestran en la Tabla 2, tienen

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

diferencias en la clasificación promedio donde sus variaciones están entre un 15 y 28%. Cuando se trata de la desviación estándar, los resultados muestran en algunos de los algoritmos un desempeño que es favorable para la reducción de la diferencia individuo-sujeto ya que no tienen una cantidad de variación muy alta, pero pese a eso, **PCA** que tiene un porcentaje alto en la clasificación y tiene valores muy altos en la desviación estándar comparados con la red sin filtros, de igual manera la Wavelet Madre **Bior 1.5** tiene unos resultados altos en la desviación estándar demostrando una gran variación en sus resultados con el data set BCI IV- 2a.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

5. CONCLUSIONES, RECOMENDACIONES Y TRABAJO FUTURO

- Este trabajo comparó dos tipos de metodologías que involucran enfoques de extracción de características con la **Transformada Wavelet** en un grupo de 6 Wavelets Madre y el filtro espacial **PCA (análisis de componentes principales)**, para identificar cuál de estos algoritmos tenía una mejor clasificación de los datos cuando se emplea un sistema BCI basado en **redes convolucionales profundas (CNN)**. Los resultados muestran que aunque se cuenta con un amplio grupo de wavelets madre, ninguna obtuvo un rendimiento similar o igual con los resultados con los que se comparó, este resultado fueron de la red convolucional sin filtro (Andrés F. Pérez et al., 2018), a diferencia del filtro PCA, el cual proporciona un enfoque confiable para la estimación de características en la clasificación de imaginación motora, ya que sus resultados fueron similares a los comparados. Sin embargo, esto prueba que varios modelos de algoritmos deben ser probados y analizados previamente, no se trata de seleccionar un filtro cualquiera sin ninguna justificación, es importante analizar qué características deben de tener los filtros diseñados, con ello llegar a tener una optimización del sistema para mejorar su rendimiento.
- Con la revisión del estado del arte sobre técnicas y metodologías de pre procesamiento y representación de información para sistemas BCI, se logra evidenciar que el trabajo que se realiza con este tipo de técnicas cada día está teniendo un crecimiento en el campo de las ciencias computacionales, aunque aún está en una etapa de crecimiento. Es importante valorar los esfuerzos que se realizan con este tipo de investigaciones, debido al potencial de aplicación que tienen, entre las que sobresale el desarrollo de tecnologías para el soporte en condiciones de discapacidad; pues, aunque no se ha llegado a resultados y sistemas

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

comerciales, los esfuerzos que se realizan para llegar a estos son cada vez más notorios.

- El diseño y la implementación del filtro PCA y La transformada Wavelet para la extracción de características en Matlab, arrojó buenos resultados, ya que su trabajo en el filtrado de las señales de EEG, para sistemas BCI, entregan a la red convolucional datos eficientes para ser clasificados en el Modelo basado en aprendizaje profundo, basándonos en el poco tiempo para el desarrollo de las representaciones y verificaciones, se podría tener mejores resultados contando con mayor tiempo para implementaciones, aunque haciendo la validación con los resultados de la red sin filtro, estos no demostraron su validez en el desarrollo de las técnicas comparadas con la literatura comparada, el filtro PCA y La Extracción de características con la Transformada Wavelet, y determinando que el aprendizaje sobre estos sistemas fue muy valioso ya que se pueden tener un buen rendimiento para la clasificación en las señales del EEG para BCI.
- Se logró evidenciar que es posible realizar un filtro de extracción de características basado en La Transformada Wavelet. La forma como se calcula una transformada wavelet está ligada a la selección de la Wavelet madre con la que se descompone una señal en diferentes componentes de frecuencia que conforman una familia de funciones que son traslaciones y dilataciones, en este proceso de filtrado se seleccionaron un grupo de wavelets madre como lo fueron: bior1.5, colf5, db1, db2 y sym1, donde se logra evidenciar que la wavelet madre db1 nivel 1, obtuvo mejores resultados en la extracción de características de los datos. Dichos datos fueron utilizados con un Clasificador CNN para el sistema BCI, sería muy valioso realizar la verificación de los niveles de descomposición por el grupo de wavelets madre, ya que estos determinar de una manera notable su funcionamiento, contando con un mayor tiempo y análisis de estos sistemas se podría llegar a tener algoritmos muchos más eficaces.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

REFERENCIAS

- Abaitua, J. de la T. (2012). Procesado De Senales Eeg Para Un Interfaz Cerebro Maquina Vci.
- Alansari, M., Kamel, M., Hakim, B., & Kadah, Y. (2018). Study of Wavelet-Based Performance Enhancement for Motor Imagery Brain-Computer Interface.
- Alonso-Valerdi, L. M., Salido-Ruiz, R. A., & Ramirez-Mendoza, R. A. (2015). Motor imagery based brain-computer interfaces: An emerging technology to rehabilitate motor deficits. *Neuropsychologia*, *79*, 354–363.
<https://doi.org/10.1016/j.neuropsychologia.2015.09.012>
- Andrés F.Pérez, Andrés F.Cardona, Jorge A. Jaramillo, & Gloria M. Díaz. (2018). Deep Convolutional Neural Networks and Power Spectral Density Features for Motor Imagery Classification of EEG Signals. In *Human Computer Interaction*.
- Ang, K. K., Chua, K. S. G., Phua, K. S., Wang, C., Chin, Z. Y., Kuah, C. W. K., ... Guan, C. (2015). A Randomized Controlled Trial of EEG-Based Motor Imagery Brain-Computer Interface Robotic Rehabilitation for Stroke. *Clinical EEG and Neuroscience*, *46*(4), 310–320. <https://doi.org/10.1177/1550059414522229>
- Ang, K. K., Guan, C., Chua, K. S. G., Ang, B. T., Kuah, C. W. K., Wang, C., ... Zhang, H. (2011). A Large Clinical Study on the Ability of Stroke Patients to Use an EEG-Based Motor Imagery Brain-Computer Interface. *Clinical EEG and Neuroscience*, *42*(4), 253–258.
<https://doi.org/10.1177/155005941104200411>
- Barachant, A., Bonnet, S., Congedo, M., & Jutten, C. (2012). Multiclass brain-computer interface classification by Riemannian geometry. *IEEE Transactions on Biomedical Engineering*, *59*(4), 920–928. <https://doi.org/10.1109/TBME.2011.2172210>
- Brunner, C., & Leeb, R. (2008). BCI Competition 2008 – Graz data set A. *Knowledge Creation Diffusion Utilization*, 1–6. <https://doi.org/10.1109/TBME.2004.827081>

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

- Bou Assi, E., Rihana, S., & Sawan, M. (2017). 33% Classification Accuracy Improvement in a Motor Imagery Brain Computer Interface. *J. Biomedical Science and Engineering*, 10(6), 326–341. <https://doi.org/10.4236/jbise.2017.106025>
- Castro, W., Peluffo, D., Noguera, M. A. P., & Castro, W. (2016). Análisis De Señales EEG Para Detección De Intenciones Motoras Aplicadas A Sistemas BCI, (November).
- Chai, R., Ling, S. H., Hunter, G. P., Tran, Y., & Nguyen, H. T. (2014). Brain-Computer Interface Classifier for Wheelchair Commands Using Neural Network with Fuzzy Particle Swarm Optimization. *IEEE Journal of Biomedical and Health Informatics*, 18(5), 1614–1624. <https://doi.org/10.1109/JBHI.2013.2295006>
- Cheng, M., Lu, Z., & Wang, H. (2017). Regularized common spatial patterns with subject-to-subject transfer of EEG signals. *Cognitive Neurodynamics*, 11(2), 173–181. <https://doi.org/10.1007/s11571-016-9417-x>
- Cho, H., Ahn, M., Ahn, S., Kwon, M., & Chan, S. (2017). EEG datasets for motor imagery brain computer interface. *Gigascience*. <https://doi.org/10.1093/gigascience/gix034>.
- Eeg, T., & Eeg, S. (n.d.). Dataset IIIa : 4-class EEG data. *Trials*, 7–9.
- Fabio, M., & Figliola, A. (2012). Métodos Tiempo-Frecuencia Basados En La Transformada Wavelet Time-Frequency Methods Based on the Wavelet Transform, 19(2), 157–168.
- Figueroa, G., Carrera, E., & Jim, A. (2012). Análisis de Componentes Principales.
- Fraga, S. F., & Mondragón, J. R. (2017). COMPARATIVO DE LOS ALGORITMOS DE DIMENSIÓN FRACTAL HIGUCHI , KATZ Y MULTIRESOLUCIÓN DE CONTEO DE CAJAS POR EVENTOS COMPARISON OF HIGUCHI , KATZ AND MULTIREOLUTION BOX-COUNTING FRACTAL DIMENSION ALGORITHMS FOR EEG WAVEFORM SIGNALS BASED ON EVENT-RELATED P, 73–83.
- Henríquez Muñoz, C. N. (2014). Estudio de Técnicas de análisis y clasificación de señales EEG en el contexto de Sistemas BCI, 156.
- HSU, W.-Y. (2012). Application of Competitive Hopfield Neural Network To Brain-Computer Interface Systems. *International Journal of Neural Systems*, 22(1), 51–62.

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

<https://doi.org/10.1142/S0129065712002979>

- Inuso, G., La Foresta, F., Mammone, N., & Morabito, F. C. (2007). Wavelet-ICA methodology for efficient artifact removal from Electroencephalographic recordings. *IEEE International Conference on Neural Networks - Conference Proceedings*, 1524–1529. <https://doi.org/10.1109/IJCNN.2007.4371184>
- Kaiser, V., Kreilinger, A., Müller-Putz, G. R., & Neuper, C. (2011). First steps toward a motor imagery based stroke BCI: New strategy to set up a classifier. *Frontiers in Neuroscience*, 5(JUL), 1–10. <https://doi.org/10.3389/fnins.2011.00086>
- Kang, H., & Choi, S. (2014). Bayesian common spatial patterns for multi-subject EEG classification. *Neural Networks*, 57, 39–50. <https://doi.org/10.1016/j.neunet.2014.05.012>
- Kouro, S., & Rodrigo, R. (2002). Tutorial introductorio a la Teoría de Wavelet. *Técnicas Modernas En Automática*, 1–8.
- Loo, C. K., Samraj, A., & Lee, G. C. (2011). Evaluation of methods for estimating fractal dimension in motor imagery-based brain computer interface. *Discrete Dynamics in Nature and Society*, 2011, 1–9. <https://doi.org/10.1155/2011/724697>
- Megat Syahirul, A. M. A., Aisyah Hartini, J., Nooritawati, M. T., Mohd Nasir, T., & Faculty of Electrical Engineering, U. T. M. (2014a). Learning Style Classification via EEG Sub-band Spectral Centroid Frequency Features. *International Journal of Electrical and Computer Engineering (IJECE)*, Vol. 4(Engineering and Science), 931~938. Retrieved from <http://iaesjournal.com/online/index.php/IJECE/article/viewFile/6833/3628>
- Megat Syahirul, A. M. A., Aisyah Hartini, J., Nooritawati, M. T., Mohd Nasir, T., & Faculty of Electrical Engineering, U. T. M. (2014b). Learning Style Classification via EEG Sub-band Spectral Centroid Frequency Features. *International Journal of Electrical and Computer Engineering (IJECE)*, Vol. 4(Engineering and Science), 931~938. Retrieved from <http://iaesjournal.com/online/index.php/IJECE/article/viewFile/6833/3628>
- Mohammadpour, M., Ghorbanian, M. K., & Mozaffari, S. (2016). Comparison of EEG signal features and ensemble learning methods for motor imagery classification. *2016 8th*

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

International Conference on Information and Knowledge Technology, IKT 2016, 288–292. <https://doi.org/10.1109/IKT.2016.7777767>

- Mrozik, K. (2017). S Pa 2017 Comparison of selected electroencephalographic signal classification methods, 36–41.
- Muñoz Cardona, J. E., & Eléctrica, M. en I. (2014). Clasificación de patrones de imaginación motora en una interfaz cerebro computador de bajo costo usando software libre, 135. Retrieved from <http://repositorio.utp.edu.co/dspace/handle/11059/4635>
- Nimit Patel, G. R. and C. R. (2012), Sap, K. A., Demmers, J. A. A., Yücel, S., Terzioğlu, P., & Özçimen, D. (2016). World â€™ s largest Science , Technology & Medicine Open Access book publisher c. *Intech*, 6, 111–133. <https://doi.org/10.5772/711>
- Reyes, A. (2013). Interfaz Cerebro Computador Mediante la Clasificiación de Señales Electroencefalográficas. *PhD Proposal*, 1. <https://doi.org/10.1017/CBO9781107415324.004>
- Tangermann, M., Müller, K. R., Aertsen, A., Birbaumer, N., Braun, C., Brunner, C., ... Blankertz, B. (2012). Review of the BCI competition IV. *Frontiers in Neuroscience*, 6(JULY), 1–31. <https://doi.org/10.3389/fnins.2012.00055>
- Tobergte, D. R., & Curtis, S. (2013). Extracción y selección de características para un sistema de brain computer interface mediante algoritmos genéticos. *Journal of Chemical Information and Modeling*, 53(9), 1689–1699. <https://doi.org/10.1017/CBO9781107415324.004>
- Turnip, A., & Hong, K. S. (2012). Classifying mental activities from EEG-P300 signals using adaptive neural networks. *International Journal of Innovative Computing, Information and Control*, 8(9), 6429–6443.
- Vaid, S., Singh, P., & Kaur, C. (2015). EEG signal analysis for BCI interface: A review. *International Conference on Advanced Computing and Communication Technologies, ACCT, 2015–April*, 143–147. <https://doi.org/10.1109/ACCT.2015.72>
- Vareka, L., & Mautner, P. (2017). Stacked autoencoders for the P300 component detection. *Frontiers in Neuroscience*, 11(MAY), 1–9.

	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

<https://doi.org/10.3389/fnins.2017.00302>

Yu, Z., & Song, J. (2017). Multi-class Motor Imagery Classification by Singular Value Decomposition and Deep Boltzmann Machine, 376–379.

Zhang, Y., Zhou, G., Jin, J., Wang, X., & Cichocki, A. (2015). Optimizing spatial patterns with sparse filter bands for motor-imagery based brain-computer interface. *Journal of Neuroscience Methods*, 255, 85–91. <https://doi.org/10.1016/j.jneumeth.2015.08.004>

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

APÉNDICE

Apéndice A

Diseño de Transformada Wavelet para Matlab

```

clear all
clc
X=[]; %creating dataset variables
Y=[];
[s, h] = sload(strcat('Cargar Señal/ Dirección donde se encuentra el archivo'));

classes = [769 770 771 772];% identifiers for each class (left, right, foot, tongue)
indexer = find(h.EVENT.TYP==769 | h.EVENT.TYP==770 | h.EVENT.TYP | h.EVENT.TYP==772);
event = h.EVENT.TYP(indexer);%labels for each class
poss = h.EVENT.POS(indexer);%position of beginning for each event
durs = h.EVENT.DUR(indexer);%duration for each event

data = cell(length(event),1); %initializing variables for data and labels
labels = cell(length(event),1);
for i=1:length(poss)%for each event

    data{i} = s(poss(i):poss(i)+durs(i),1:22);
    labels{i} = repmat(event(i),durs(i)+1,1);%including in the final dataset

end

%Wavelet Transform
c1 = cell(length(event),22);
l1 = cell(length(event),22);
for trial=1:288

    for canal=1:22
        D = data{trial}{:,canal};
        D(isnan(D)) = 0;
        [c1{trial,canal},l1{trial,canal}] = wavedec(D, Nivel de descomposición ejemplo: 1,'Wavelet
Madre ejemplo: db1');
    end
end
matriz = cell2mat(c1);

```

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

```
matrizlabels = cell2mat(labels);
```

```
%Signal
dlmwrite('data555.txt',matriz,' ');
dlmwrite('labels555.txt',matrizlabels,' ');
```

Apéndice B

Diseño de PCA para Matlab

```
clear all
clc
X=[]; %creating dataset variables
Y=[];
for arc=1:1
    clear s h
    [s, h] = load(strcat('Cargar Señal/ Dirección donde se encuentra el archivo'));
    s = s(:,1:22);%only 22 first electrodes are eeg signal
    classes = [769 770 771 772];% identifiers for each class (left, right, foot, tongue)
    indexer1 = find(h.EVENT.TYP==769);
    event1 = h.EVENT.TYP(indexer1);%labels for each class
    poss1 = h.EVENT.POS(indexer1);%position of beginning for each event
    durs1 = h.EVENT.DUR(indexer1);%duration for each event

    indexer2 = find(h.EVENT.TYP==770);
    event2 = h.EVENT.TYP(indexer2);%labels for each class
    poss2 = h.EVENT.POS(indexer2);%position of beginning for each event
    durs2 = h.EVENT.DUR(indexer2);%duration for each event

    indexer3 = find(h.EVENT.TYP==771);
    event3 = h.EVENT.TYP(indexer3);%labels for each class
    poss3 = h.EVENT.POS(indexer3);%position of beginning for each event
    durs3 = h.EVENT.DUR(indexer3);%duration for each event
```

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

```

indexer4 = find(h.EVENT.TYP==772);
event4 = h.EVENT.TYP(indexer4);%labels for each class
poss4 = h.EVENT.POS(indexer4);%position of beginning for each event
durs4 = h.EVENT.DUR(indexer4);%duration for each event

```

```

%initializing variables for data and labels

```

```

data1 = [];
labels1 = [];
data2 = [];
labels2 = [];
data3 = [];
labels3 = [];
data4 = [];
labels4 = [];

```

```

for i=1:length(poss1)%for each event
    data1 = [data1;s(poss1(i):poss1(i)+durs1(i),:)];
    labels1 = [labels1;repmat(event1(i),durs1(i)+1,1)];

```

```

end

```

```

for i=1:length(poss2)%for each event
    data2 = [data2;s(poss2(i):poss2(i)+durs2(i),:)];
    labels2 = [labels2;repmat(event2(i),durs2(i)+1,1)];

```

```

end

```

```

for i=1:length(poss3)%for each event
    data3 = [data3;s(poss3(i):poss3(i)+durs3(i),:)];
    labels3 = [labels3;repmat(event3(i),durs3(i)+1,1)];

```

 Institución Universitaria	INFORME FINAL DE TRABAJO DE GRADO	Código	FDE 089
		Versión	03
		Fecha	2015-01-22

end

for i=1:length(poss4)%for each event

data4 = [data4;s(poss4(i):poss4(i)+durs4(i),:)];

labels4 = [labels4;repmat(event4(i),durs4(i)+1,1)];

end

end

[coeff1,score1,latent1] = pca (data1(:,:),'Algorithm','svd');

[coeff2,score2,latent2] = pca (data2(:,:),'Algorithm','svd');

[coeff3,score3,latent3] = pca (data3(:,:),'Algorithm','svd');

[coeff4,score4,latent4] = pca (data4(:,:),'Algorithm','svd');

X1 = [score1;score2;score3;score4];

Y1 = [labels1;labels2;labels3;labels4];

%Signal

dlmwrite('datapca.txt',coeff, ' ');

dlmwrite('datalabelspca.txt',Y, ' ');

Apéndice B

Registro de actividades

Institución Universitaria		MODALIDAD TRABAJO DE GRADO PRODUCTO OBTENIDO EN TALLERES O LABORATORIOS DEL ITM			Código	FDE 146
Registro de actividades y cumplimiento de horas / Talleres o Laboratorios de DOCENCIA					Versión	02
					Fecha	2015-09-30
Documento de identidad: 1128 385 773 Nombre completo del estudiante: JONN CAMILO DIPINA OUYAYO Programa académico ITM: ING. TELECOMUNICACIONES Nombre completo del Docente Asesor: ANDRÉS FELIPE PÉREZ ZAPATA / GLORIA DÍAZ Fecha de iniciación del producto (aaaa/mm/dd): 2018/03/02 Fecha de terminación del producto (aaaa/mm/dd): Nombre Taller o Laboratorio: LABORATORIO MÁQUINAS INTELIGENTES Y RECONOCIMIENTO DE PATRONES Ubicación: Campus:						
Fecha	Actividad desempeñada por el estudiante	Hora ingreso	Hora salida	Total horas	Firma Laboratorista	Firma Estudiante
01/02	REVISIÓN LITERATURA	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	SELECCIONAR REFERENCIAS TRABAJO	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	ESCRITURA DE ANÁLISIS LITERATURA	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	DISEÑO FILTROS	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	IMPLEMENTACIÓN FILTROS.	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	PROCESAMIENTO SEÑAL PED CONV.	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	ANÁLISIS RESULTADOS PED CONV.	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	REVISIÓN LITERATURA ARTÍCULO	2	6PM	4	Andrés Pérez	<i>[Firma]</i>
01/02	ESCRITURA ARTÍCULO	2	6PM	4	<i>[Firma]</i>	<i>[Firma]</i>
01/02	ANÁLISIS DISEÑO PED CONV.	2	6PM	4	<i>[Firma]</i>	<i>[Firma]</i>

