

UNIVERSIDAD PEDAGÓGICA NACIONAL
FACULTAD DE CIENCIA Y TECNOLOGÍA
DEPARTAMENTO DE TECNOLOGÍA
MAESTRÍA EN TECNOLOGÍAS DE LA INFORMACIÓN
APLICADAS A LA EDUCACIÓN

ESTILOS COGNITIVOS Y ADQUISICIÓN DE SEÑALES DE IMAGINERÍA DEL
HABLA POR MEDIO DE SEÑALES EEG

BOGOTÁ, 2021

UNIVERSIDAD PEDAGÓGICA NACIONAL
FACULTAD DE CIENCIA Y TECNOLOGÍA
DEPARTAMENTO DE TECNOLOGÍA
MAESTRÍA EN TECNOLOGÍAS DE LA INFORMACIÓN
APLICADAS A LA EDUCACIÓN

ESTILOS COGNITIVOS Y ADQUISICIÓN DE SEÑALES DE IMAGINERÍA DEL
HABLA POR MEDIO DE SEÑALES EEG

TESIS DE MAESTRÍA PRESENTADA POR:

ANA SILVIA CLAROS COLLAZOS

DIRIGIDA POR:

Dr. LUIS CARLOS SARMIENTO VELA

BOGOTÁ, 2021

Derechos de autor

Los gestores del proyecto declaran que el presente trabajo es original y la autoría es de los mismos; en la medida que se ha requerido de investigaciones de otros autores se han dado los respectivos créditos. (Artículo 42, parágrafo 2, del Acuerdo 031 del 4 de diciembre de 2007 del Consejo Superior de la Universidad Pedagógica Nacional.



Este trabajo de grado se encuentra bajo una Licencia Creative Commons de Reconocimiento – No comercial – Compartir igual, por lo que puede ser distribuido, copiado y exhibido por terceros si se muestra en los créditos. No se puede obtener ningún beneficio comercial y las obras derivadas tienen que estar bajo los mismos términos de licencia que el trabajo original.

Dedicatoria

A mi hija Samantha, ya que ha soportado mi ausencia mientras terminaba mi maestría y siempre me demostró su amor incondicional cuando volvía a casa.

A mis padres, quienes han creído en mis capacidades y confiado plenamente en mí para la realización de este proyecto de vida.

Y a mis hermanas y hermanos, especialmente a Dasmii, Yésica y Servando, ya que de ellos he recibido el apoyo económico y moral tanto en mi pregrado y ahora en mi posgrado, a ellos, infinitas gracias.

Agradecimientos

Mi más profunda admiración y agradecimiento a mi asesor de tesis, el Doctor Luis Carlos Sarmiento Vela, quién contribuyó con su arduo conocimiento y compromiso en este proyecto de investigación, además, por permitirme afianzar mis conocimientos en el campo de señales cerebrales.

A Sergio, Julián, al Doctor Jan Bacca que con sus aportes permitieron forjar las raíces de esta investigación y además, por permitirme ser parte de este proyecto de Investigación.

A Colciencias, por el apoyo financiero para esta investigación del Ministerio de Ciencia, Tecnología e Innovación -MINCIENCIAS-, Colombia, según contrato de financiamiento RC 838/2017, código: 110177758402. Este proyecto también utilizó hardware del programa de subvenciones NVIDIA GPU.

A la Universidad Pedagógica Nacional y a sus docentes y administrativos de la maestría en Tecnologías de la Información Aplicadas a la Educación, por los espacios ofrecidos y sus amplios conocimientos.

Tabla de contenido

Introducción.....	10
Capítulo 1. Presentación de la investigación.....	12
Necesidad de la investigación.....	12
Pregunta de investigación.....	16
Propósito de la investigación.....	16
Objetivos de la investigación.....	17
Objetivo general.....	17
Objetivos específicos.....	17
Capítulo 2: Marco teórico y estado del arte.....	19
Estilos cognitivos y la dimensión DIC.....	19
Instrumento de medida de los estilos cognitivos para la clasificación de los sujetos en las dimensiones DIC.....	24
Imaginería del habla.....	26
Señales Electroencefalográficas.....	32
Características de un aparato EEG.....	33
Prótesis de miembro superior.....	33
Capítulo 3. Metodología.....	35
Tipo de investigación.....	35

Diseño de la investigación.....	35
Población y muestra	35
Variables.....	36
Análisis de datos.....	36
Prueba de Figuras Enmascaradas para determinar el Estilo Cognitivo (DIC) .	37
Protocolo experimental para la adquisición de tareas de imaginería del habla....	37
Adquisición de señales	39
Tareas.....	39
Preprocesamiento de las señales cerebrales.....	41
Método de Deep learning con Convolutional neural network (CNN).....	44
Capítulo 4. Resultados.....	45
Capítulo 4. Discusiones y conclusiones	55
Limitaciones	59
Recomendaciones para Futuras Investigaciones	60
Referencias	60

Lista de tablas

Tabla 1. Características de los estilos cognitivos en las dimensiones DIC.....	34
Tabla 2. Clasificación de los sujetos de acuerdo a su estilo cognitivo.....	57
Tabla 3. Media y desviación estándar para los algoritmos Shallow CNN (1), EEGNet (2) y CNNeeg1-1(3).....	58
Tabla 4. Resultado prueba de esfericidad de Mauchly.....	59
Tabla 5. Relación modelos de Shallow CNN, EEGNet y CNNeeg1-1 y relación de los Estilos cognitivos con los modelos CNN.....	60
Tabla 6. Media y desviación estándar de los estilos cognitivos y comparación por parejas entre los estilos cognitivos en las dimensiones DIC.....	61
Tabla 7. Comparación por parejas entre los modelos Shallow CNN (1), EEGNet (2) y CNNeeg1-1(3).....	62

Lista de figuras

Figura 1. Un ítem de la prueba eft para la evaluación del estilo cognitivo.....	35
Figura 2. Instalación de electrodos.....	49
Figura 3. Intervalos de tiempo para el proceso de la experimentación.....	50
Figure 4. Arquitectura CNNeeg1-1.....	54
Figura 5. Medidas marginales.....	6

Introducción

Durante los últimos años, el cerebro ha sido un tema de estudio importante debido a la interpretación de sus funciones, dentro de las que se encuentra la relación entre la conducta y la forma en la que aprende el individuo (Uva, 2017).

Las funciones hemisféricas específicas del cerebro humano, han dado lugar a la distinción de los estilos cognitivos, permitiendo así identificar la forma particular en la que las personas procesan la información, actúan en un proceso de aprendizaje, características de su personalidad, su relación con el entorno, entre otras (Hayes y Allinson, 1998).

Particularmente, el hemisferio izquierdo juega un papel fundamental en la conducta humana. Este tiene un predominio en la actividad lingüística, dentro de sus funciones está la elaboración del lenguaje proposicional y la emisión de palabras, debido a su relación directa con las áreas de Broca y de Wernicke, encargadas de la producción del lenguaje y la comprensión de las palabras (Portellano, 1992; Desrosiers, 1993).

Adicional a lo anterior, en este hemisferio se lleva a cabo la producción interna de palabras sin la emisión de un sonido verbal, a lo que se le denomina imaginación del habla (Tamm, et al. 2020; Martin, et al. 2017) que junto con los estilos cognitivos en las dimensiones dependencia e independencia de campo, son el tema principal de esta investigación.

La presente investigación consta de 5 capítulos. En el primero, se realiza la presentación de la investigación y enuncian las preguntas de investigación y los objetivos. El segundo, hace mención al marco teórico y el estado del arte, mostrando los constructos de los estilos cognitivos, la imagería del habla y las señales electroencefalográficas. En el tercero, se lleva a cabo la metodología, en donde se muestra la forma procedimental en la que se llevó a cabo la investigación. El cuarto capítulo, corresponde a los resultados, en el que se plantea las condiciones iniciales y se desarrolla un análisis de medias repetidas. Y por último, se presenta el capítulo de discusiones y conclusiones de la investigación.

Capítulo 1. Presentación de la investigación

Necesidad de la investigación

La forma en la que se procesa la información juega un papel fundamental en la conducta y aprendizaje de las personas de acuerdo al registro de la actividad cerebral en los diferentes hemisferios, permitiendo así distinguir el estilo cognitivo como predominio funcional de un hemisferio a otro (Portellano, 1992). Es importante tener en cuenta el comportamiento y las aptitudes que caracterizan al individuo y su relación con las estrategias de aprendizaje utilizadas, lo que puede estar conectado con el estilo cognitivo, como se registra en los diferentes estudios (Evans, Richardson & Waring 2013; Kozhevnikov, 2007).

El estilo cognitivo puede entenderse como el modo habitual que tienen las personas para resolver un problema, percibir el conocimiento, pensar y recordar (Tennant, 1988). También se puede describir como el conjunto de métodos en los cuales las personas llevan a cabo la realización de una actividad y el modo en que procesan la información (Hederich, 2007). Existe una gran variedad de dimensiones de los estilos cognitivos, entre los que se encuentra la dependencia y la independencia de campo (DIC). De acuerdo con Witkin, Moore, Goodenough, & Cox (1977), los sujetos dependientes de campo, se caracterizan por realizar búsquedas de referentes externos para procesar y estructurar la información, y los sujetos independientes de campo, suelen tener comportamientos individuales en la búsqueda de datos y se atiende al yo como un referente primario en actividades psicológicas.

En el contexto educativo, la relevancia de identificar los estilos cognitivos de los sujetos, se centra en que de acuerdo a la forma en que estos perciben la información, resuelven problemas, piensan y recuerdan el contenido estudiado y se evidencian los resultados al momento en que realizan una evaluación (López, 2011). La adquisición de los diferentes conocimientos se logra a través de diversas estrategias, por lo que aquí también juega un papel fundamental los procesos de enseñanza y aprendizaje en el aula, para identificar la forma en que los estudiantes aprenden ya que así como algunos apropián conceptos de forma visual, hay quienes los comprenden mejor de forma gráfica (García y Galán, 2009).

De acuerdo con López, Hederich & Camargo (2011) los estilos cognitivos tienen una relación directa con el aprendizaje autorregulado y el logro académico, en diferentes niveles del proceso de aprendizaje en los estudiantes. Por otro lado, Pérez (2015) afirma, que los estilos cognitivos se relacionan con el rendimiento académico en las diferentes áreas como las matemáticas y el lenguaje, obteniendo diferencias en los procesos cognitivos, los cuales se desarrollan en la ejecución de tareas y acciones propias de cada área del conocimiento.

Dentro de los procesos cognitivos, el lenguaje es una de las actividades cerebrales más complejas que realiza el ser humano, este puede definirse como toda forma de comunicación por medio del pensamiento, concepto o sentimiento a partir de un sistema de representación simbólica, que es desarrollada en múltiples áreas del cerebro. Los símbolos utilizados en el lenguaje son por lo general letras, sílabas, palabras, oraciones, etc., y se generan por los “órganos del habla” que permiten la producción de sonidos por medio del

lenguaje hablado (Grodzinsky, Shapiro y Swinney, 2000). En el contexto educativo la forma de comunicación predomina en los ambientes de aprendizajes, donde el estudiante y el profesor se comunican por lo general de forma oral (fonemas) o en forma escrita utilizando grafemas. Al respecto, (Egan, 1999) describe que en el ámbito educativo, la literatura infantil, especialmente los cuentos, han tomado relevancia sobre todo cuando se trata de orientar procesos difíciles, obligatorios y propios de los primeros años de escolaridad, como lo es el aprender a escribir (codificar) y aprender a leer (decodificar) de forma convencional. Para el caso de las personas sordas se utiliza el lenguaje de señas como forma de comunicación (Patiño, 2016; Amezcua y Amezcua, 2018).

En lo que respecta la comunicación oral, el cerebro puede emitir letras, sílabas o palabras internamente sin emitir ningún sonido verbal, a esto se le denomina, imaginería del habla (Tamm, et al, 2020; Martin, et al, 2017; Martin, et al, 2014). Las señales de la imaginería del habla, pueden ser registradas gracias a diferentes tecnologías como la interfaz cerebro computador (BCI), que es un sistema de conexión de la actividad cerebral con una máquina u ordenador (Sarmiento, 2019). Es importante mencionar que los sistemas BCI basados en señales electroencefalográficas (EEG) registran la actividad cerebral por medio de electrodos ubicados en el cuero cabelludo, y que a diferencia de otras tecnologías como la electrocorticografía (ECoG), éstas son técnicas no invasivas (Carvajal, 1998).

Se han realizado diferentes aportes en el desarrollo de BCI con imaginería del habla por medio de señales EEG, en donde se registran vocales, sílabas, palabras, entre otras. Las ventajas de este método para el reconocimiento de tareas, es que son técnicas no invasivas y no requieren de altos entrenamientos como es el caso de las imágenes motoras, así como el

no generar fatigas musculares o cognitivas mientras se capturan este tipo de señales, además, no necesitan un estímulo externo. Esta investigación, se basa específicamente en la clasificación de imaginaria de las palabras (/abrir/, /cerrar/ y /parar/).

En relación con métodos de machine learning e imaginaria de palabras, se presentan métodos clásicos para extraer características como: The discrete wavelet transform (Torres et al. 2013; Coretto et al, 2017; Moctezuma et al. 2018; Moctezuma et al. 2019); Common spatial patterns (CSP) (Wang et al. (2013); Wavelet packet decomposition (Salama et al. 2013); Matriz de covarianza (Nguyen et al. 2017), entre otros; a partir de la utilización de electrodos ubicados por lo general de acuerdo al sistema internacional 10-20 (Coretto et al. 2017; Nguyen et al. 2017; Hashim, et al. 2017; García, et al 2019).

Por otro lado, existe un campo que ha sido promisorio por su habilidad en el reconocimiento de patrones cuando hay un alto volumen de datos a la hora de clasificar palabras de imaginaria del habla, como es el caso de Deep Learning (Li, et al. 2020; Jingwei, et al.2015). La arquitectura más común al momento de utilizar DL es Convolutional Neural Network (CNN) (Cooney, et al. 2019; Tamm, et al. 2020; Cooney, et al. 2020), para poder clasificar las palabras en español /arriba/, /abajo/, /derecha/, /izquierda/, /adelante/ y /atrás/ (Cooney, et al. 2019; Lee, et al. 2020; Tamm, et al. 2020; Cooney, et al. 2020).

Aunque las investigaciones relacionadas con Deep Learning han sido exitosas para el reconocimiento de palabras de imaginaria del habla sigue siendo un desafío y se busca mejorar su porcentaje de clasificación. De otro lado, y dada la relevancia de nuevos

métodos de los estilos cognitivos, lo que se busca en este trabajo, es que por medio de señales cerebrales específicamente en imaginación del habla, se pueda explorar si es posible identificar los estilos cognitivos a partir de la clasificación de este tipo de señales cerebrales, ya que no se ha encontrado en la literatura elementos en donde se pueda determinar la relación de estas dos variables. De acuerdo a lo anterior se propone la siguiente pregunta de investigación:

Pregunta de investigación

¿Existen diferencias significativas entre sujetos de diferente estilo cognitivo en la dimensión Dependencia/Independencia de campo y los algoritmos para la clasificación de las palabras de imaginación del habla /abrir, cerrar, parar/?

Propósito de la investigación

El propósito de esta investigación es poder evaluar si es posible identificar los estilos cognitivos de los sujetos cuando desarrollan tareas de imaginación del habla en la clasificación de las palabras /abrir/, /cerrar/ y /parar/. Para poder validar las dimensiones de los estilos cognitivos, se le aplicará el test de figuras enmascaradas (EFT), el cual consiste en la visualización de figuras geométricas inmersas de forma compleja, el fin de la realización de la prueba EFT, es determinar la manera en la que las personas procesan la información y si hacen un análisis riguroso de los contenidos, o si por el contrario, perciben el conocimiento de forma estructural o paulatina debido a que se desorientan con facilidad. Por otra parte, se desarrollará un nuevo algoritmo basado en Deep Learning con los

algoritmos de referencia Shallow CNN, EEGNet y CNNeeg1-1 para clasificar las palabras de imaginación del habla /abrir/, /cerrar/ y /parar/ a partir de la creación de una base de datos privada. Posteriormente, se hará una comparación entre estas dos variables, para mostrar si existen diferencias significativas entre los algoritmos propuestos y los estilos cognitivos en la dimensiones dependencia e independencia de campo.

Objetivos de la investigación

Objetivo general.

Categorizar a los sujetos durante tareas de imaginación del habla en las dimensiones de los estilos cognitivos a través del reconocimiento de señales electroencefalográficas.

Objetivos específicos.

Desarrollar un algoritmo de procesamiento de señales basado en Deep Learning para la clasificación de tareas de imaginación de palabras (/abrir/, /cerrar/ y /parar/) por medio de la captura de señales electroencefalográficas.

Identificar si existen diferencias significativas entre el algoritmo desarrollado CNNeeg1-1 y los algoritmos de referencia Shallow CNN, EEGNet utilizados en sujetos para clasificar tareas de imaginación del habla: /abrir/, /cerrar/ y /parar/.

Determinar si existen diferencias significativas en los estilos cognitivos para sujetos clasificados en las dimensiones Dependencia, intermedio e independencia de campo a

través de los clasificadores Shallow CNN, EEGNet y CNNeeg1-1 para sujetos que desarrollan tareas de imagería del habla: /abrir/, /cerrar/ y /parar/.

Capítulo 2: Marco teórico y estado del arte

Este proyecto de investigación tiene aspectos fundamentales que permiten dar claridad sobre los conceptos básicos que se deben tener en cuenta para la elaboración de la presente investigación: Por un lado, se aborda el concepto de estilos cognitivos para categorizar a los sujetos en las dimensiones dependencia/independencia de campo; por otro lado, se define qué es la imaginería del habla haciendo énfasis en los lóbulos del cerebro en los cuales se produce el lenguaje (área de Brocka y Wernicke). También, se plantea la definición de señales electroencefalográficas que son las que permite el registro de la actividad cerebral.

De otro modo, se exponen los antecedentes que respaldaron esta investigación, divididos en dos categorías: En la primera, se hace énfasis en la caracterización de los sujetos basado en los estilos cognitivos en la dimensión Dependencia/Independencia. Y en la segunda, se hace referencia a los estudios relacionados con la adquisición de señales electroencefalográficas (EEG) y la producción de imaginería del habla.

Estilos cognitivos y la dimensión DIC

En esta investigación, se define al estilo cognitivo como la forma habitual en la que el individuo procesa y organiza la información, así como la manera en que la perciben y la recuerda Tennant (1988). También se define como el conjunto de métodos en los cuales el individuo lleva a cabo la realización de una actividad y el modo en que procesan la

información (Hederich, 2007). Diversas investigaciones establecen que la forma en que se adquiere el aprendizaje, es de acuerdo a las habilidades particulares que tienen las personas para apropiarse de conceptos, ya que desde temprana edad el individuo crea una adaptación particular y profunda para aprender y que difícilmente con el paso del tiempo logra modificarla (Curry, 1983). Por su parte, Feuerstein (1980) plantea que existe la posibilidad de que las personas modifiquen su estilo cognitivo, permitiendo así que se obtenga con mayor éxito el logro de aprendizaje. Por consiguiente, la identificación del estilo cognitivo permitirá que las personas desarrollen destrezas y habilidades que le permitan mejorar su aprendizaje (Kim, 1993; Díaz, 1996).

De otra forma, el estilo cognitivo se reduce a la dimensión bipolar que describe al individuo de acuerdo a las características particulares de cada polo (Valencia, 2017). Dentro de las dimensiones de los estilos cognitivos, se encuentran la de adaptación-innovación (Kirton, 1976), reflexividad-impulsividad (Kagan, 1963), dimensión holístico-analítico (Riding, 1995), etc. Para fines de esta investigación, se establece las dimensiones de los estilos cognitivos dependencia e independencia de campo (DIC) Witkin, Hertzman, Meissner Lewis, Machover, y Wapner (1954), debido a los múltiples resultados que evidencian la implicación directa que tiene sobre el logro de aprendizaje (López, Sanabria y Sanabria, 2014; Archer, 2003; Hsu y Dwyer, 2004; Angeli y Valanides, 2013).

Dentro de las características particulares de la dimensión DIC, están los dependientes de campo (DC), que son aquellos sujetos que tienden a ser más sensibles a las señales externas, necesitando de una constante supervisión y apoyo, además, tienden a buscar referentes externos para procesar y estructurar la información, prefieren el trabajo en grupo, estas

personas se ven fácilmente influenciadas por la opinión de los demás. Por otro lado, se encuentra la dimensión independiente de campo (IC), en donde el estudiante procesa la información de forma analítica y fragmentadora, estos sujetos suelen organizar, estructurar y enfatizar los contenidos, investigan más allá de lo visto en clase con el fin de fortalecer su aprendizaje, estos sujetos no se ven influenciados por otras personas, así como no les afecta la aprobación o desaprobación de superiores, sin embargo, aunque tienen un carácter activo, son personas a las que se les dificulta los vínculos sociales.

Las investigaciones hechas por Archer (2013); Hsu y Dwyer (2004) y Palmquist y Kim (200) determinan que las personas independientes de campo al momento de hallar búsqueda de información en la web, suelen ser autoeficientes y efectivos en la exploración de recursos sin la necesidad de tener a alguien a su lado para que los guíe; caso contrario al estilo dependiente, ya que presentan algunas dificultades para interactuar con los entornos computacionales. Por su parte Liu y Reed, 1994; López (2010) reportan que dentro de la existencia de las DIC existe una zona intermedia en donde se comparte características particulares de los dos extremos, a los sujetos que están dentro de estas zonas se les denomina intermedio de campo (INT).

En la investigación hecha por López, Hederich, & Camargo (2011) se realizó una revisión de la literatura para identificar las relaciones teóricas y empíricas entre el estilo cognitivo, el aprendizaje autorregulado y el logro académico. Los resultados mostraron que hay una correspondencia sistemática entre capacidad de autorregulación y altos logros de aprendizaje en casi todos los contenidos y niveles de enseñanza. Además, existe una correlación entre algunas características estilísticas propias de los estudiantes

independientes de campo y aquellos estudiantes que regulan su aprendizaje. En Camacho y Martínez (2012) se exploró el efecto diferencial de la implementación de dos métodos para la enseñanza de la escritura (silábica y global), sobre el logro de aprendizaje en niños con estilos cognitivos diferentes en la dimensión DIC, estos resultados muestran que existen ventajas en el método global sobre el método silábico en términos generales, específicamente para los niños dependientes e intermedio de campo en seis de los ocho indicadores examinados. De igual forma, se identificaron estudios que han evaluado el rendimiento académico de los estudiantes, de acuerdo a la forma de procesar la información (Zapata 2010; Pérez, 2015). Para el caso de la investigación realizada por Tinajero y Páramo (1998), participaron 408 sujetos, para llevar a cabo un análisis entre el estilo cognitivo en la dimensión DIC y el logro académico en diferentes asignaturas, para determinar el efecto de la inteligencia. En Leader y Klein (1996), participaron 75 sujetos, en donde se buscaba evaluar la eficacia de cuatro herramientas computacionales tipo hipertexto para la búsqueda de información, así como el desarrollo y búsqueda autónoma de contenido. Por último, en la investigación hecha por López, Ibáñez, y Chiguasuque (2014) se registraron 85 estudiantes, los cuales fueron divididos en dos grupos, estos interactuaron con un ambiente hipertexto llamado "Softri" para poder identificar el logro de aprendizaje durante su interacción en la resolución de problemas de triángulos rectángulos.

En la tabla 1, se presenta un resumen de las características de los estilos cognitivos en ambos polos (Jonassen y Grabowsky (1993), citado por Ramos, 2006).

Tabla 1

Características de los estilos cognitivos en las dimensiones DIC.

Dependencia de campo	Independencia de campo
Global	Analítico
Acepta estructura	Genera estructura
Dirigido externamente	Dirigido internamente
Atento a la información social	Desatento hacia las claves sociales
Solucionador de conflictos	Filosófico, cognitivo
Sociable y gregario	Individualista
Orientado a la afiliación	Distante de las relaciones sociales
Interpersonal	Intrapersonal
Necesita amistad	Reservado, solitario
Convencional, tradicional	Experimentador
Influenciado por el destacado	Generador de hipótesis propias
Orientado por los hechos	Orientado por los conceptos
Adquiere hecho no relacionados	Da coherencia a la información
Acepta ideas como se presentan	Analiza conceptos
Influido por el formato y la estructura	Poco influido por el formato y la estructura
Toma decisiones y sentimientos de otros	Orientación impersonal
Sensible a los otros	Insensible a ocurrencias sociales
Afectado por el estrés	Ignora el estrés extremo


Fuente: tomado y adaptado de Jonassen y Grabowsky (1993), citado por Ramos (2006) y Duque (2020).

Instrumento de medida de los estilos cognitivos para la clasificación de los sujetos en las dimensiones DIC

Con el fin de identificar a los sujetos en las dimensiones de los estilos cognitivos independientes y dependiente de campo, se realiza de forma manual o digital el test de Figura Enmascaradas (EFT, por sus siglas en inglés), el cual consiste en retener en mente figuras simples para luego poder identificarlas en figuras complejas con igual forma y tamaño Witkin, Oltman, Raskin y Karp (1971). En la figura 1 se muestra un ejemplo de la prueba EFT en versión en línea, desarrollada por el Grupo de Estilos Cognitivos, de la Universidad Pedagógica Nacional, utilizada para examinar el estilo cognitivo de dependencia-independencia de campo de H. Witkin.

Figura 1

Un ítem de la prueba eft para la evaluación del estilo cognitivo



Fuente. Tomado de (Hederich, et al. 2015)

Diferentes trabajos de investigación, han aplicado la prueba EFT, con el fin de examinar a los sujetos en los estilos cognitivos en las dimensiones DIC. En López y Col., (2012), los sujetos IC, presentan habilidades de procesamiento analítico y perceptual a la hora del desenmascaro de figuras, contrario de lo que ocurre con los sujetos DC, puesto que la solución de este tipo de actividades requieren de observación inmersa dentro de representaciones simbólica, limitando su percepción. En Páramo (2013), los resultados indicaron que a diferencia de los sujetos DC, los sujetos ID mostraron mejores habilidades en el desenmascaramiento de figuras complejas. Adicional, los sujetos IC, tendrían mayor facilidad a la hora de retraerse del contexto enmascarador, que los sujetos DC, facilitando así la información perceptiva en la atención de los elementos más relevantes (Tinajero & Páramo, 2013). Finalmente, se realiza una validación de la versión digital de la prueba EFT, adaptada por el grupo de estilos cognitivos COGNITEK de la Universidad Pedagógica Nacional Vargas (2016), el cual parte de la versión GEFT de Witkin (1961). En donde se enfatiza en la importancia de la validez y confiabilidad de los resultados del test a partir de las propiedades psicométricas de pruebas psicológicas como la teoría clásica del test TCT (del inglés *International Test Commission*), propuesta por Tornimbedi y col., (2004) y citado por Sarmiento (2021). Los principales requerimientos para la validación y confiabilidad de la prueba, es que el coeficiente alfa de Cronbach (superior a 0.70, en investigación científica debe ser superior a 0.80 y para toma de decisiones sobre individuos debe ser 0.90, preferiblemente 0.95 o más), aclarando que la validez obedece más al constructo que al instrumento (Sarmiento, 2021).

Imaginería del habla

El lenguaje es una función cerebral que le permite al ser humano expresar pensamientos y sentimientos por medio de la palabra (Sleeper, 2006). El procesamiento del lenguaje se divide en dos funciones básicas que se originan en el hemisferio izquierdo: la primera es aquella en la cual se recibe la información de los órganos como el oído, la vista o incluso el tacto, y la segunda, se centra en aquellos órganos que emiten un sonido o una señal, como la laringe o la lengua, las extremidades superiores, entre otros, para la producción de palabras. Aquellos sonidos o señales que recibe el cerebro del medio exterior para la comprensión del lenguaje, se encuentra en el área de Wernicke, ubicada en la parte posterior de la circunvolución superior en el hemisferio izquierdo. Por otro lado, el cerebro produce la información para dar a conocer esas palabras adquiridas de forma sensorial a través de la corteza motora que es la que controla los músculos usados para pronunciarlas y se encuentra en el área de Broca, ubicada en el lóbulo frontal, cerca de la tercera circunvolución (Donoso,1998).

Estas señales se pueden capturar con diferentes tecnologías como la interfaz cerebro computador (BCI), (Sarmiento, 2019). La BCI es un sistema de conexión entre la actividad cerebral para el control de dispositivos externos como un computador o un dispositivo mecatrónico. Es importante mencionar que los sistemas BCI basados en señales electroencefalográficas (EEG) registran las actividades cerebrales por medio de electrodos ubicados en el cuero cabelludo, y a diferencia de otras tecnologías, estas son técnicas no invasivas. Las principales dificultades para identificar las señales de imaginería del habla

con EEG son la adquisición y el pre procesamiento de estas, puesto que se debe realizar en tiempo real para lograr una velocidad y una respuesta considerable (Carvajal, 1998).

Existen métodos no invasivos de BCI que registran la actividad cerebral posicionando electrodos en el cuero cabello de las personas para la toma de señales, se utilizan equipos como las imágenes de resonancia magnética funcional (fMRI) y sus valores se toman en voxels, y la electroencefalografía (EEG), cuyos valores se representan en microvoltios (μV); ésta última de especial importancia por el efecto sobre el análisis tanto en el dominio del tiempo como el de la frecuencia, que en combinación con técnicas de imágenes, aumenta significativamente la precisión en el reconocimiento del patrón cerebral asociado a la actividad cognitiva (Martin, et al. 2018).

Dentro de los métodos existentes para trabajar con EEG y BCI, están la imaginería motora (Edelman, et al. 2015; Ito, et al. 2010) P300 (Kaongoen y Jo (2017) y los potenciales evocados visuales de estado estable (SSVEP) (Bakardjian, et al. 2010). Una de las limitaciones de los métodos como la imaginería motora, es la complejidad y la alta concentración en las tareas que se deben realizar; y para el caso de los métodos SSVEP y P300, se requiere de un estímulo visual, auditivo o háptico. Las aplicaciones de BCI que ha presentado mayor interés por la comunidad científica dada su precisión y naturalidad, es la imaginería del habla. Se describe la imaginería del habla como el acto de pronunciar letras o palabras internamente sin emitir ningún sonido verbal (Tamm, et al. 2020; Martin, et al. 2017; Martin, et al. 2014). Las ventajas de este método para el reconocimiento de tareas, es que son técnicas no invasivas y no se requieren de altos entrenamientos como es el caso de

las imágenes motoras, así como el no generar fatigas musculares o cognitivas mientras se capturan este tipo de señales, además, no necesitan un estímulo externo.

En relación con métodos de machine learning e imaginaria del habla, se han realizado diferentes investigaciones que describen las mejores características y clasificadores para el reconocimiento de patrones como energía, potencia, tiempo y frecuencia, que se relacionan con el habla imaginada.

Dentro de los principios básicos para el reconocimiento del habla imaginada con métodos de machine Learning para el reconocimiento de palabras como (/arriba/, /abajo/, /izquierda/, /derecha/, /seleccionar/, /adelante/ y /atrás/, entre otras, se tienen los siguientes vectores de características: The discrete wavelet transform (DWT) (Torres, et al. 2013; Coretto, et al. 2017; Moctezuma, et al. 2019; Moctezuma, et al. 2018) Common spatial patterns (CSP) (Wang, et al.2013); Wavelet packet decomposition (Salama, et al. 2014); Matriz de covarianza (Nguyen, et al. 2017); medida de conectividad basada en covarianza y una medida de conectividad basada en correlación cruzada lineal máxima (Qureshi, et al. 2017); Mel Frequency Cepstral Coefficients (MFCC) (Hashim, et al. 2017).

Dentro de las ubicaciones de los electrodos en un procedimiento de captura de datos con EEG y el uso de machine learning están: La concatenación en dos configuraciones distintas, 14 canales completos y 4 canales ubicados en las áreas de Broca y Wernicke (Torres, et al. 2013); la primera configuración de electrodos tiene 30 canales que cubren todo el cerebro y el segundo tiene 15 canales que cubren el área de Broca y el área de Wernicke (Wang, et al. 2013); 1 electrodo (Salama, et al. 2014); 6 electrodos ubicados en

F3, F4, C3, C4, P3 y P4 (Coretto et al., 2017); 64 electrodos ubicados según el sistema 10-20 (Nguyen et al., 2017); cuatro conjuntos de selección de canal (CS), lóbulo frontal inferior izquierdo (área de Broca) (CS1), lóbulo temporal superior izquierdo (área de Wernicke) (CS2), una combinación de las dos áreas anteriores (CS3) y todo el cerebro (CS4) (Qureshi et al., 2017); 14 electrodos ubicados en AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 y AF4 (Moctezuma et al., 2019; Moctezuma et al., 2018); y 14 electrodos ubicados según el sistema 10-20 (Hashim, et al. 2017; García, et al. 2019). El número de sujetos que han participado en las diferentes bases de datos de habla imaginada son: 4 sujetos (Hashim et al., 2017); 7 sujetos (Coretto et al., 2017); 8 sujetos (Qureshi et al., 2019); 15 sujetos (Salama et al., 2014; Nguyen et al., 2017) y 27 sujetos (Moctezuma et al., 2019; Moctezuma & Molinas Cabrera, 2018; García et al., 2019)

Por otro lado, en la búsqueda de optimización de algoritmos que permitan diferenciar mediante procesos de automatización inteligentes, patrones de señales relacionados como el habla encubierta de palabras, se han analizado diferentes clasificadores: Random Forest (RF) (Torres et al., 2013; Salama et al., 2014; Moctezuma et al., 2019; Moctezuma et al., 2018); support vector machine (SVM) (Torres et al., 2013; Wang et al., 2013; Coretto et al., 2017; Salama et al., 2014) ; Naive Bayes (NB) (Torres et al., 2013; García et al., 2019); Discriminant Analysis (DA), Self-Organizing Map (SOM) y Feed Forward Back-propagation (FFBP) (Coretto et al., 2017); Relevance Vector Machine (RVM) (Nguyen et al., 2017); extreme learning machine (ELM) (Qureshi et al., 2017); k-Nearest Neighbor (k-NN) (Hashim et al., 2017).

Las dificultades que presentan los métodos clásicos de machine learning está el necesitar del diseño de nuevos algoritmos que permitan la identificación de la señal y los clasificadores adecuados. Para superar las dificultades anteriores, se requiere de enfoques que permitan una clasificación óptima de las señales EEG hacia mejores capacidades de generalización y aplicaciones más flexibles Mathew et al., (2020). En la actualidad existe un campo que ha sido promisorio por la habilidad en el reconocimiento de patrones cuando hay un alto volumen de datos, como es el caso de la arquitectura Deep Learning (DL) (Li et al., (2020); Jingwei et al., (2015) destacándose por ser una clase de aprendizaje automático que funciona con mayor efectividad con datos no estructurados y permite a la vez que los modelos computacionales aprendan características de forma progresiva a partir de datos en múltiples niveles (Tamm et al., 2020; Mohammad et al., 2021). Así como, su capacidad para aprender representaciones de características a partir de datos sin procesar y a la vez se logra un rendimiento competitivo en la tarea objetivo (Bengio et al., 2017; Heilmeyer et al., 2018; Balaji et al., 2017; Roy et al., 2017).

En este campo, es importante mencionar las arquitecturas de DL para el reconocimiento de imagería de palabras: Artificial Neural Networks (ANN) (Balaji et al., 2017); Deep Neural Network (DNN) (Panachakel et al., 2020); Siamese Neural Network (Lee et al., 2020); Convolutional Neural Network (CNN) (Cooney et al., 2019; Tamm et al., 2020; Cooney et al., 2020).

Por medio de DL se han utilizado en las bases de datos palabras como: /Yes/ and /No/ in English ('Haan' and 'Na' in Hindi) / Balaji et al., 2017); palabras cortas /in/ y /out/, y palabras largas /in/ y /cooperate/ / Panachakel et al., 2020); palabras en español /arriba/

/abajo/, /derecha/, /izquierda/, /adelante/ y /atrás/ (Cooney et al., 2019; Lee et al., 2020; Tamm et al., 2020; Cooney et al., 2020).

Dentro de las ubicaciones de los electrodos que se han utilizado con los métodos de DL para el reconocimiento de imaginería de vocales se tiene: 32 electrodos, la mayor parte de la grabación se centró en el área de Broca y Geshwind-Wernicke [24]; 9 electrodos ubicados de acuerdo al sistema 10-20 [25] y 6 electrodos ubicados en F3, F4, C3, C4, P3 y P4 (Cooney et al., 2019; Lee et al., 2020; Tamm et al., 2020; Cooney et al., 2020).

Por otro lado, se presenta las precisiones que han alcanzado los métodos de DL para el reconocimiento de palabras de habla imaginada de EEG y los sujetos que han participado en la recolección de datos. Con ANN un accuracy de 85.20% con 5 sujetos; también, se alcanzó un accuracy con DNN de 71.8%; para el caso de Siamese Neural Network un accuracy de 31.40% con 15 sujetos; para CNN un accuracy de 62,37% con 15 sujetos, 23.98% con 15 sujetos y para 15 sujetos se ha alcanzado una exactitud con Shallow CNN, Deep CNN y EEGNet de 24.88%, 24.42% y 24.46, respectivamente.

Aunque las investigaciones relacionadas con Deep Learning han sido exitosas para el reconocimiento de palabras de imaginería del habla sigue siendo un desafío y se busca mejorar su porcentaje de clasificación, por lo que en esta investigación se presenta un algoritmo novedoso de DL, nuevos métodos de preprocesamiento y que el costo computacional en el procesamiento de datos sea menor.

Señales Electroencefalográficas

Las señales electroencefalográficas (EEG) permiten estudiar la actividad eléctrica cerebral. Dado que las medidas de EEG clínicas se obtienen mediante electrodos situados en la superficie del cuero cabello, estas señales representan una suma muy general de potenciales originados en una cantidad de neuronas muy grande, próxima a los electrodos.

El encefalograma es el registro clínico más empleado para la evaluación funcional del cerebro. Es una técnica no invasiva y se emplea desde hace mucho tiempo para la detección rápida de estados disfuncionales del cerebro. (Carvajal, 1998, p. 51)

El EEG es el encargado de leer el sistema nervioso y a partir de él, poder realizar el análisis pertinente. El sistema nervioso es un conjunto de tejidos dentro del cuerpo, encargados de captar y procesar rápidamente las señales internas y externas, tomando el control y coordinación sobre los demás órganos, para así, lograr una oportuna y eficaz interacción con el medio ambiente cambiante. La unidad básica del sistema nervioso es la neurona, la cual tiene la capacidad de comunicarse eléctricamente con otras células, sean éstas nerviosas o no. La información viaja entre neuronas por medio de impulsos eléctricos que se transmiten de unas neuronas a otras. Estos impulsos, se reciben de otras neuronas en las dendritas y pasan a través de la neurona hasta ser conducidas por el axón a los terminales de salida, los cuales pueden conectarse con otra neurona, fibras musculares o glándulas. (Abaitua, 2012, p. 17)

Características de un aparato EEG

El panel de conexiones es una de las características principales de un aparato EEG permitiendo en la mayoría de los casos conectar el electrodo escogido en cualquier canal del instrumento. Hay una variedad de interruptores rotatorios como un panel de pulsadores.

De acuerdo con Tompkins (1998, p. 52) el dispositivo de lectura en un electroencefalógrafo clínico es un registrador de pluma multicanal con una pluma para cada canal. La velocidad normal del papel es de 30 mm por segundo para mejorar los detalles de señales de alta frecuencia. Algunos disponen de una tercera velocidad de 15 mm por segundo para ahorrar papel durante el tiempo de colocación. También es posible utilizar un osciloscopio para la lectura del EEG, pero no da un registro permanente. En algunos casos, en particular en aplicaciones de investigación, el osciloscopio se utiliza junto con el junto con el registrador de pluma para ver la señal hasta que se observe un cambio particular o una característica en la señal. De esta forma sólo se registra las partes interesantes. Muchos electroencefalógrafos tienen previstas además interfaces en unos registrados de cinta analógico que permita registrar y reproducir la señal EEG.

Prótesis de miembro superior

Una prótesis es un dispositivo o producto de aplicación externa que se encarga de reemplazar una parte faltante del cuerpo o suplir las funciones perdidas de este (Normas de ortoprotésica de la OMS. Parte 1, 2017). Dentro de los tipos de prótesis, se encuentran aquellas en la que la persona ha sufrido amputación de miembro superior, bien sea por

accidentes laborales, infecciones, deformidades congénitas, cuando han víctimas del conflicto armado, etc.

Las prótesis más utilizadas para pacientes que han sufrido amputaciones de miembro superior son: prótesis estéticas, donde solo interesa la apariencia física; prótesis funcionales pasivas, las cuales se ajustan en movimientos de prensión específicos; prótesis funcionales activas, que utilizan energía externa, son mecatrónicas y están controladas por señales bioeléctricas; según el nivel de amputación, desarticulados (hombro, codo, muñeca), prótesis bajo el codo y prótesis encima del codo y según el material constitutivo, mecánicas (convencionales), electrónicas e híbridas. (Páez, 2008). Hay dos aspectos decisivos para que el paciente use o no la prótesis: el primero, es la facilidad de control para generar los diferentes procesos de aprendizaje motor en el desarrollo de tareas de manipulación, de forma que no se convierta en un problema para el paciente; y el segundo, es la semejanza estética y funcional (biomecánica) de la mano. (Páez, 2008, p.17).

Las prótesis de extremidad superior son controladas por lo general por electromiografía (EMG) ya que estos tipos de prótesis son las más populares en el mercado (Farina, 2014) utilizando una parte específica del cuerpo para controlarla. No obstante, el proceso de capacitación para su función es exigente y aumentar sus grados de libertad es una tarea complicada. Por otra parte, se encuentra las neuroprótesis (Ashok, 2014) que a partir de la actividad cerebral de la corteza y el uso de sensores directamente en el cuero cabelludo por medio de la cirugía (técnica invasiva), se registran las señales, por lo que genera un riesgo en el paciente al momento de colocar los sensores directamente. Lo anterior conlleva a hacer uso de la electroencefalografía para el registro de señales

cerebrales, por ser una técnica no invasiva y su alta resolución de tiempo (Villamizar et al., 2019).

Capítulo 3. Metodología

Tipo de investigación

Este estudio, se realizó bajo el tipo de investigación cuasi experimental, en donde se categorizó a los sujetos en las dimensiones de los estilos cognitivos como Dependientes-Independientes de campo, y además, se desarrolló un algoritmo de clasificación para el reconocimiento de tareas de imaginería del habla.

Diseño de la investigación

Para esta investigación se aplicó un diseño factorial 3*3 en el cual se incluye las siguientes condiciones: estilos cognitivos de los estudiantes (Dependencia-Independencia de campo), algoritmos de referencia (Shallow CNN y EEGNet) y el modelo propuesto (CNNeeg1-1) para clasificar las palabras de imaginería del habla /abrir/, /cerrar/ y /parar/.

Población y muestra

En este este trabajo de investigación, participaron 30 estudiantes universitarios sanos. La muestra estuvo conformada por 18 hombres (60%) y 12 mujeres (40%) entre un

rango de edad de 23 a 56 años (MD=33.72, SD=10.075) y ubicados en los estratos económicos 2 y 3.

Variables

Las variables que se estimadas son las siguientes:

a. Variables dependientes: relacionadas con los algoritmos de clasificación de tareas de imaginaria del habla EEGNet, Shallow CNN y CNNeeg1-1.

b. Variables asociadas: estilos cognitivos en las dimensiones dependencia de campo, intermedio de campo e independencia de campo.

Análisis de datos

Para el tratamiento de las variables, se realizó un análisis ANOVA mixto de medidas repetidas para medir si existen diferencias significativas entre los estilos cognitivos en las dimensiones, dependencia, intermedio e independencia de campo; así como, determinar si hay diferencias significativas entre los algoritmos de referencia CNN, EEGNet y el algoritmo desarrollado CNN eeg1-1; y por último, si hay significancia entre las dimensiones de los estilos cognitivos y los modelos de CNN. Para la obtención de estos resultados, se utilizó el software *Statistical Package for the Social Science - IBM SPSS*, versión 25.

Instrumentos

Prueba de Figuras Enmascaradas para determinar el Estilo Cognitivo (DIC)

La adaptación del test de figuras enmascaradas de Witkin (1961) fue la prueba que se utilizó en esta investigación, para identificar el estilo cognitivo de los participantes en las dimensiones DIC. Se aplicó una versión en línea que consta de 18 preguntas, que consiste en identificar una figura simple inmersa dentro de una figura compleja, para responderse en un tiempo límite preestablecido. La media y la desviación estándar del EFT fue (M=11.20, SD=4.52) sobre un puntaje máximo de 18 puntos, el valor mínimo fue de 2 y el máximo de 18. Para categorizar a los participantes en las dimensiones dependiente, intermedio e independientes de campo, se definió terciles para el puntaje total del test: 10 estudiantes dependientes de campo (primer tercil), 10 intermedios de campo (segundo tercil) y 10 estudiantes independientes de campo (tercer tercil), este resultado fue homogéneo debido al número reducido de la muestra (30 sujetos).

La prueba EFT aplicada, fue validada con estudiantes colombianos por el grupo de investigación de Estilos Cognitivos COGNITEK, de la Universidad Pedagógica Nacional y se ha aplicado en diferentes investigaciones por su validez y confiabilidad al momento de realizar el alfa de Cronbach de 0,85 y 0,9. (López et al., 2012).

Protocolo experimental para la adquisición de tareas de imaginería del habla

La experimentación se llevó a cabo en el laboratorio de Cognición y Sistemas Inteligentes de la Universidad Pedagógica Nacional (Bogotá- Colombia).

Cada sujeto estuvo sentado en una silla cómoda y se les colocó un equipo de electroencefalografía g.®USBamp-Research de g.tec con 32 electrodos ubicados en el hemisferio izquierdo, que cubre las áreas de Broca y de Wernicke; para posicionar el casco en la cabeza de cada sujeto se utilizaron los indicadores de Cz y T3. De igual forma se les colocó en la frente un electrodo que indica la tierra (GND) y otro en la oreja izquierda que representa la referencia (REF) (ver figura 2). Se utilizó un gel conductor para el contacto entre los electrodos y el cuero cabelludo. Finalmente, se ubicó una fuente luminosa a un metro de distancia para indicar el momento en el cual el sujeto debía pensar y pronunciar las palabras /abrir/, /cerrar/ y /parar/. Las personas permanecieron con los ojos abiertos durante toda la experimentación para que pudieran ver el cambio de luminosidad y así realizar cada tarea de forma correcta.

Figura 2

Instalación de electrodos



Adquisición de señales

Para el registro de datos de imaginería del habla, se utilizó el amplificador bioseñal g.®USBamp-Research de gama alta de g.tec con una tecnología USB 2.0 y con una resolución de 24 bits. Para la adquisición de señales electroencefalográficas se utilizaron 32 electrodos ubicados en el área de lenguaje (Broca y Wernicke), con una frecuencia de muestreo de 2400 Hz.


Tareas

Las personas debían pronunciar y pensar las palabras /abrir/, /cerrar/ y /parar/ (una por una)

En los primeros 3 segundos (led apagado) la persona estaba relajada; en los siguientes 2 segundos (led rojo encendido) la persona pronunciaba la palabra respectiva en forma continua; durante los siguientes 3 segundos (led apagado) la persona estuvo nuevamente relajada; en los próximos 4 segundos (led verde encendido) la persona pensó la palabra respectiva en forma continua (ver figura 3). El procedimiento anterior se repitió 25 veces por cada palabra y entre el cambio de una palabra a otra habrá un tiempo de descanso de 5 minutos.

Figura 3

Intervalos de tiempo para el proceso de la experimentación



.En la figura 3, se observan los intervalos de tiempo en los cuales los sujetos realizaron cada tarea de imaginación del habla. En los intervalos (1-7200, 7201-12000, 12001-19200, 19201-28800...). El sujeto pronunciará y pensará la respectiva palabra. El sujeto estará en estado de relajación en los intervalos (1-7200); en el intervalo (7201-12000 y led rojo) el sujeto pronunciará la respectiva palabra; el sujeto estará de nuevo en estado de relación en (12001-19200); el sujeto pensará de forma silenciosa la respectiva palabra en los intervalos (19201-28800) y se repetirá el ciclo en otros intervalos de tiempo.

Las señales cerebrales se procesaron con el método Deep Learning en donde $p=32$ electrodos (E1,... E32) fueron ubicados en el hemisferio izquierdo (área de Broca Wernicke).

Arquitectura CNNeeg1-1

La arquitectura propuesta está conformada por 3 bloques de preprocesamiento de señales de imaginación del habla para cada una de las 3 CNNs, con aplicación al reconocimiento de parejas de palabras imaginadas y una etapa para la función one-against—

one (1-1) que permite la clasificación de la imaginación de palabras (/abrir/, /cerca/ y /parar/). A continuación, se describe la arquitectura propuesta basada en DL.

Preprocesamiento de las señales cerebrales

La arquitectura propuesta consta de 3 bloques de preprocesamiento que filtran y adecuan las señales cerebrales para entregarla a cada uno de los CNN. Cada bloque de preprocesamiento está conformado principalmente por una etapa de filtraje utilizando Adaptive-projection intrinsically transformed (APIT-MEMD) y una etapa de transformación de las señales utilizando análisis espectral. Con relación a las señales cerebrales registradas para cada sujeto, se seleccionan los intervalos en los cuales los sujetos realizaron las respectivas tareas de imaginación del habla. Para el procesamiento de las señales cerebrales, se seleccionó trials con un ancho de 64 muestras y un solapamiento del 85%.

Para el proceso de filtraje de las señales de imaginación del habla, se seleccionó el método de APIT-MEMD dado que las señales tienen características no lineales y no estacionarias [R57]. El método de APIT-MEMD tiene la particularidad de separar las señales multivariadas en Intrinsic mode functions (IMFs). El algoritmo Adaptive-projection intrinsically transformed (APIT-MEMD) presenta los siguientes pasos [R57]:

1. Para cada frame de entrada multidimensional $[x(t)]_{t=1}^T$ y cada operación de desplazamiento $x(t)$ hacer la descomposición de la matriz de covarianza como $C = E\{\mathbf{ss}^T\} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T$ donde $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n]$ es la matriz de eigenvectores, y $\mathbf{\Lambda} =$

$\text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_n\}$ es la matriz de eigenvalores. En este caso el valor más grande de eigenvalores estará en correspondencia con el eigenvector \mathbf{v}_1 .

2. Tome el primer componente principal y construya un vector que apunte en la dirección diametralmente opuesta a la dirección $\mathbf{v}_{01} = -\mathbf{v}_1$.
3. Usando la sequencia de Hammersley sobre una esfera de muestreo uniforme, construya un conjunto de K vectores de dirección $\{p^{\theta_k}\}_{k=1}^K$.

4. Calcule las distancias euclidianas desde cada uno de los vectores de dirección uniforme hasta \mathbf{v}_1 .

5. Relocalice la mitad de los vectores de proyección $p_{\mathbf{v}_1}^{\theta_k}$, más cercano a \mathbf{v}_1 usando

$$\hat{p}_{\mathbf{v}_1}^{\theta_k} = \frac{\hat{x}_{\mathbf{v}_1}^{\theta_k} + \alpha \mathbf{v}_1}{|\hat{x}_{\mathbf{v}_1}^{\theta_k} + \alpha \mathbf{v}_1|}, \text{ donde } \alpha \text{ se utiliza para controlar la densidad de los vectores}$$

reubicados.

6. La otra mitad de todos los vectores de proyección uniformes, $\hat{p}_{\mathbf{v}_1}^{\theta_k}$, más cercana a

$$\mathbf{v}_{01}, \text{ son reubicados usando } \hat{p}_{\mathbf{v}_{01}}^{\theta_k} = \frac{\hat{x}_{\mathbf{v}_{01}}^{\theta_k} + \alpha \mathbf{v}_{01}}{|\hat{x}_{\mathbf{v}_{01}}^{\theta_k} + \alpha \mathbf{v}_{01}|}, \text{ donde } \alpha \text{ se utiliza para controlar la}$$

densidad de los vectores reubicados.

7. Proyecte la señal multidimensional $[x(t)]_{t=1}^T$ a lo largo de los vectores de dirección encontrados en los procedimientos 5 y 6.

8. Encuentre el instante de tiempo $t_i^{\theta_j}$ correspondiente al máximo del conjunto de datos proyectados, donde θ_j es el ángulo de la esfera dimensional $(n - 1)$ y j es el índice de los vectores de dirección.

9. Interpole $\left[t_i^{\theta_j} \left(t_i^{\theta_j} \right) \right]$ para calcular las curvas envolventes $[e^{\theta_j}(t)]_{j=1}^J$.

10. Estimar la media de las curvas envolventes para el conjunto J de vectores de dirección:

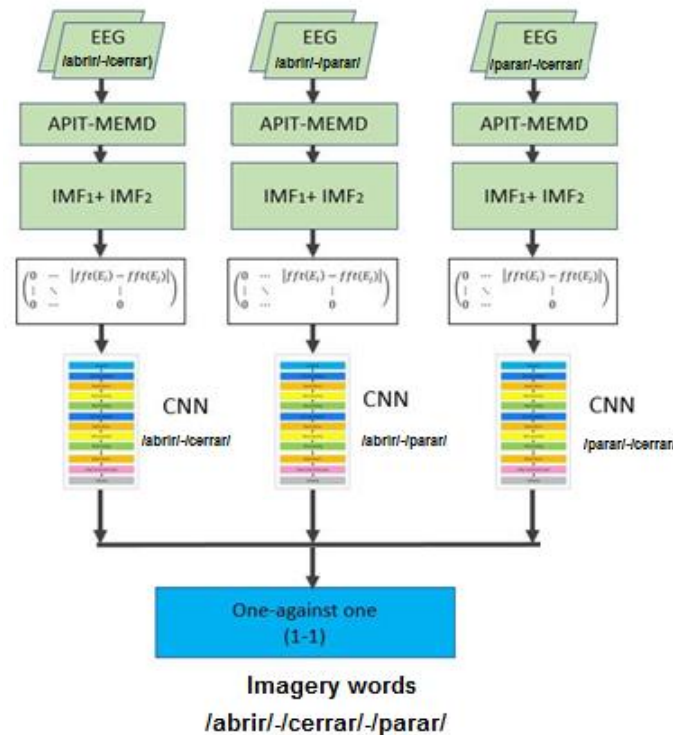
$$m = \frac{1}{J} \sum_{j=1}^J e^{\theta_j(t)}$$

11. Calcular el residuo $d(t) = x(t) - m(t)$.
12. Repetir los pasos anteriores hasta que el residuo encuentre las condiciones de un IMF para las señales multivariadas.

De los IMFs resultado de aplicar el algoritmo APIT-MEMD a las señales cerebrales, se seleccionan para esta arquitectura los dos primeros IMFs (IMF1, IMF2) los cuales poseen una frecuencia central de aproximadamente 30 Hz y 15 Hz, respectivamente (Figure 3). Estos dos IMFs se seleccionan y se suman para cada uno de los 32 electrodos.

Figure 4

Arquitectura CNNeeg1-1.



Fuente. Tomado y adaptado de Sarmiento (2021)

Método de Deep learning con Convolutional neural network (CNN)

La arquitectura propuesta está conformada por 3 CNNs cada uno especializado en el aprendizaje por Deep learning de parejas de imaginería del habla: CNN (/abrir/-parar/), CNN (/abrir/-cerrar/), CNN (/parar/-cerrar/). El conjunto de imágenes para entrenar cada CNN especializada en imaginería del habla, por individuo, es de 2548 imágenes.

Para el proceso de entrenamiento se utilizó una GPU modelo NVIDIA GeForce GTX 1080 Ti con memoria GDDR5X de próxima generación de 11 Gbps y un gran buffer de cuadros de 11 GB y la implementación del algoritmo se realizó con el toolbox Deep Learning de Matlab. Para el entrenamiento de las redes CNN se utilizó el optimizador

stochastic gradient descent with momentum (SGDM), se seleccionó la razón de aprendizaje con un valor de 0.01, el número de épocas de 50. El 70% de los datos se utilizó para entrenamiento y el 30% para validación. A continuación, se describe la arquitectura de la respectivas CNNs.

Capítulo 4. Resultados

Para poder determinar el estilo cognitivo de los participantes en la dimensión dependiente- independiente de campo, se utilizó el test de figuras enmascaradas o prueba EFT. El objetivo de esta prueba es evaluar la capacidad que tiene la persona para hallar figuras geométricas inmersas de forma compleja. El test consta de 18 preguntas y se aplicó a través de un software en línea, en el cual la persona tenía un límite de tiempo para responder, y al finalizar la prueba, le arrojaría el resultado obtenido. Por otro lado, se realizó un entrenamiento intra-subject para los algoritmos Shallow CNN, EEGNet y

CNNeeg1-1 utilizando la base de datos de la clasificación de las palabras de imaginación del habla /abrir/, /cerrar/ y /parar/.

Para el desarrollo de la experimentación se les colocaron 32 electrodos a las personas en las áreas de Broca y Wernicke. Se realizó un análisis ANOVA mixto de medidas repetidas a partir de los resultados obtenidos en la clasificación de los algoritmos CNN, EEGNet y CNNeeg1-1 y los Estilos Cognitivos, en las dimensiones Dependiente, intermedio e independiente de campo, haciendo una comparación entre estos, a partir de señales electroencefalográficas relacionadas con la imaginación de las palabras /abrir/, /cerrar/ y /parar/. El proceso de entrenamiento sujeto a sujeto de las CNN utilizó en forma aleatoria un 70% de los datos para entrenamiento y un 30% de los datos para la validación.

El Test de figuras enmascaradas mostró los resultados obtenidos en la tabla 2, en donde 10 personas son dependientes de campo (1), 10 intermedios de campo (2) y 10 personas son independientes de campo (3).

Tabla 2

Clasificación de los sujetos de acuerdo a su estilo cognitivo

Factores inter-sujetos			
		Etiqueta de valor	N
Percentile Group of EstiloCognitivo	1	Dependiente de campo	10
	2	Intermedio de campo	10
	3	Independient e de campo	10

En este análisis, también se establecieron las variables intra-sujetos e inter-sujetos. La variable intra-sujetos compara el accuracy de los modelos CNN Shallow CNN (1), EEGNet (2) y CNNeeg1-1(3) y la variable inter-sujetos, compara el accuracy de los estilos cognitivos en las dimensiones dependiente de campo (1), intermedio de campo (2) e independiente de campo (3).

En la tabla 3, se muestra las medias y la desviación estándar que hay entre las variables intra-sujetos (Modelos de CNN) y la variables inter-sujetos (dimensiones de los estilos cognitivos) como sigue: para el entrenamiento inter-sujetos en el caso de Shallow CNN y la dimensión dependiente de campo (1) se alcanza ($M=0.6561$, $SD=0.0792$). Luego, EEGnet para la dimensión dependiente de campo (1), presenta un accuracy de ($M=0.8039$, $SD=0.0611$) y por último, para CNNeeg1-1 y la dimensión independiente campo se obtuvo una media y una desviación estándar de ($M= 0.8966$, $SD=0.0469$).

Por otro lado, se obtienen resultados de la variable inter-sujeto para el caso de Shallow CNN y la dimensión intermedio de campo (2) de ($M=0.6894$, $SD=0.0561$). Ahora, para el caso de EEGnet en la dimensión intermedio de campo (2) se tiene un accuracy de

($M=0.8338$, $SD=0.477$) y por último, para CNNeeg1-1 y el estilo cognitivo intermedio de campo (2) se obtuvo una media y una desviación estándar de ($M= 0.9092$, $SD=0.0360$).

Para el caso del modelo Shallow CNN y la dimensión independiente de campo (3) se obtiene un accuracy ($M=0.6548$, $SD=0.0544$), para EEGNet y la dimensión independiente de campo (3) se obtiene un resultado de ($M=0.8325$, $SD=0.0483$) y por último para el modelo CNNeeg1-1 y el estulo cognitivo en la dimensión independiente de campo (3) se obtuvo una media y una desviación estándar de ($M=0.8991$, $SD=0.0365$).

Tabla 3

Media y desviación estándar para los algoritmos Shallow CNN (1), EEGNet (2) y CNNeeg1-1(3)

Estimaciones				
Medida: Accuracy				
Model_CNN	Media	Desv. Error	Intervalo de confianza al 95%	
			Límite inferior	Límite superior
1	,667	,012	,643	,691
2	,832	,010	,813	,852
3	,902	,007	,887	,917

En la tabla 4, la prueba de Mauchly indicó que el supuesto de esfericidad se cumplió ($X(2) = 2.347$, $p > 0,05$).

Tabla 4*Resultado prueba de esfericidad de Mauchly*

Prueba de esfericidad de Mauchly ^a							
Medida: Accuracy							
Efecto intra-sujetos	W de Mauchly	Aprox. Chi-cuadrado	gl	Sig.	Greenhouse-Geisser	Épsilon ^b	
						Huynh-Feldt	Límite inferior
Model_CNN	,914	2,347	2	,309	,921	1,000	,500

Prueba la hipótesis nula de que la matriz de covarianzas de error de las variables dependientes con transformación ortonormalizada es proporcional a una matriz de identidad.

a. Diseño : Intersección + EstiloCognitivo
Diseño intra-sujetos: Model_CNN

b. Se puede utilizar para ajustar los grados de libertad para las pruebas promedio de significación. Las pruebas corregidas se visualizan en la tabla de pruebas de efectos intra-sujetos.

Las pruebas de efectos intra-sujetos que se observa en la tabla 5, muestran que hay diferencias significativas entre la clasificación realizada por los tres modelos CNN para el imaginario del habla de las palabras con $F(0.437, 49.71) = 746.175$, $p < 0.001$, $\eta^2 = 0.965$. Por el contrario, los resultados muestran que no existe una interacción significativa entre la variable intrasujetos (Modelo de CNN) e intersujetos (Estilos cognitivos) relacionado al accuracy $F(0.437, 49.71) = 1.546$, $p > 0.001$, $\eta^2 = 0.103$.

Tabla 5

Relación modelos de Shallow CNN, EEGNet y CNNeeg1-1 y relación de los Estilos cognitivos con los modelos CNN

Pruebas de efectos intra-sujetos									
Medida: Accuracy									
Origen		Tipo III de suma de cuadrados	gl	Media cuadrática	F	Sig.	Eta parcial al cuadrado	Parámetro sin centralidad	Potencia observada ^a
Model_CNN	Esfericidad asumida	,730	2	,365	575,989	,000	,955	1151,979	1,000
	Greenhouse-Geisser	,730	1,806	,404	575,989	,000	,955	1040,238	1,000
	Huynh-Feldt	,730	2,000	,365	575,989	,000	,955	1151,979	1,000
	Límite inferior	,730	1,000	,730	575,989	,000	,955	575,989	1,000
Model_CNN * EstiloCognitivo	Esfericidad asumida	,001	4	,000	,413	,799	,030	1,650	,138
	Greenhouse-Geisser	,001	3,612	,000	,413	,780	,030	1,490	,133
	Huynh-Feldt	,001	4,000	,000	,413	,799	,030	1,650	,138
	Límite inferior	,001	2,000	,001	,413	,666	,030	,825	,110
Error(Model_CNN)	Esfericidad asumida	,034	54	,001					
	Greenhouse-Geisser	,034	48,762	,001					
	Huynh-Feldt	,034	54,000	,001					
	Límite inferior	,034	27,000	,001					

a. Se ha calculado utilizando alpha = ,05

Conforme al análisis inter-sujetos, vinculada al tipo de estilo cognitivo, se identifica que no hay diferencias significativas entre los sujetos en las dimensiones dependencia de campo ($M=0.795$, $SD=0.016$), intermedio de campo ($M=0.811$, $SD=0.016$) e independiente de campo ($M=0.796$, $SD=0.016$) ($p>0.05$) (tabla 5).

En la tabla 6, se presenta la media y la desviación estándar de los estilos cognitivos en la dimensión DIC como sigue: dependiente de campo ($M=0.795$, $SD=0.16$), intermedio de campo ($M=0.811$, $SD=0.16$) e independiente de campo ($M=0.796$, $SD=0.16$), así, se concluye que los sujetos intermedios de campo ($M=0.811$) tiene la media más alta, seguido de los independientes de campo ($M=0.796$) y por último, los dependientes de campo ($M=0.796$).

Tabla 6.

Media y desviación estándar de los estilos cognitivos y comparación por parejas entre los estilos cognitivos en las dimensiones DIC

Estimaciones						
Medida: Accuracy						
Percentile Group of EstiloCognitivo	Media	Desv. Error	Intervalo de confianza al 95%			
			Límite inferior	Límite superior		
Dependiente de campo	,795	,016	,762	,827		
Intermedio de campo	,811	,016	,779	,843		
Independiente de campo	,796	,016	,763	,828		

Comparaciones por parejas						
Medida: Accuracy						
(I) Percentile Group of EstiloCognitivo	(J) Percentile Group of EstiloCognitivo	Diferencia de medias (I-J)	Desv. Error	Sig. ^a	95% de intervalo de confianza para diferencia ^a	
					Límite inferior	Límite superior
Dependiente de campo	Intermedio de campo	-,016	,022	1,000	-,073	,040
	Independiente de campo	-,001	,022	1,000	-,057	,056
Intermedio de campo	Dependiente de campo	,016	,022	1,000	-,040	,073
	Independiente de campo	,015	,022	1,000	-,041	,072
Independiente de campo	Dependiente de campo	,001	,022	1,000	-,056	,057
	Intermedio de campo	-,015	,022	1,000	-,072	,041

Se basa en medias marginales estimadas
a. Ajuste para varias comparaciones: Bonferroni.

En relación a los resultados obtenidos con anterioridad, se presenta el análisis post-hoc, basado en Bonferroni, resaltando las diferencias significativas entre parejas de variables en técnicas de clasificación (accuracy) de imaginería de palabras. Los resultados indican que hay diferencias significativas entre el modelo Shallow CNN (M=0.667, SD=0.012) y el modelo EEGNet (M=0.832, SD=0.012) de la base de datos de imaginería de palabras ($p<0.05$). También se tiene que hay diferencias significativas entre el modelo Shallow CNN (M=0.667, SD=0.012) y el modelo CNNeeg1-1 (M=0.902, SD=0.07) para la clasificación de imaginería de palabras ($p<0.05$). De igual forma, se tiene diferencias

significativas entre el modelo EEGNet (M=0.832, SD=0.012) y el modelo CNNeeg1-1 (M=0.902, SD=0.07) ($p < 0.05$) (tabla 6). De esta manera, se tiene que el modelo que presenta la media más alta es CNNeeg1-1 (M=0.902), seguido del modelo EEGNet (M=0.832).

Tabla 7

Comparación por parejas entre los modelos Shallow CNN (1), EEGNet (2) y CNNeeg1-1(3)

Comparaciones por parejas						
Medida: Accuracy						
(I) Model_CNN	(J) Model_CNN	Diferencia de medias (I-J)	Desv. Error	Sig. ^b	95% de intervalo de confianza para diferencia ^a	
					Límite inferior	Límite superior
1	2	-.166 [*]	.006	.000	-.182	-.149
	3	-.235 [*]	.007	.000	-.252	-.217
2	1	.166 [*]	.006	.000	.149	.182
	3	-.069 [*]	.005	.000	-.083	-.056
3	1	.235 [*]	.007	.000	.217	.252
	2	.069 [*]	.005	.000	.056	.083

Se basa en medias marginales estimadas

*. La diferencia de medias es significativa en el nivel .05.

b. Ajuste para varias comparaciones: Bonferroni.

La tabla 8, muestra la significancia entre los modelos de CNN y las dimensiones de los estilos cognitivos. Se observa que existen diferencias significativas entre la dimensión dependiente de campo (M=0.795, SD=0.16) y los modelos Shallow CNN, EEGNet y CNNeeg1-1. También se muestra, que hay diferencias significativas entre la dimensión intermedio de campo (M=0.811, SD=0.16) y los modelos Shallow CNN, EEGNet y CNNeeg1-1. Por último, se logra identificar que existen diferencias significativas entre el estilo cognitivo independiente de campo (M=0.76, SD=0.16) y las técnicas de CNN

Shallow CNN, EEGNet y CNNeeg1-1. Por consiguiente, se tiene que el estilo cognitivo que presenta la media más alta es el intermedio de campo (M=0.811), seguido del estilo cognitivo Independiente de campo (M=0.796).

Tabla 8

Comparación entre parejas de los modelos Shallow CNN (1), EEGNet (2), CNNeeg1-1 (3) y los estilos cognitivos en las dimensiones dependiente, intermedio e independiente de campo

Comparaciones por parejas							
Medida: Accuracy							
Percentile Group of EstiloCognitivo	(I) Model_CNN	(J) Model_CNN	Diferencia de medias (I-J)	Desv. Error	Sig. ^b	95% de intervalo de confianza para diferencia ^b	
						Límite inferior	Límite superior
Dependiente de campo	1	2	-,175 [*]	,011	,000	-,203	-,146
		3	-,240 [*]	,012	,000	-,271	-,210
	2	1	,175 [*]	,011	,000	,146	,203
		3	-,066 [*]	,009	,000	-,089	-,042
	3	1	,240 [*]	,012	,000	,210	,271
		2	,066 [*]	,009	,000	,042	,089
Intermedio de campo	1	2	-,144 [*]	,011	,000	-,173	-,116
		3	-,220 [*]	,012	,000	-,250	-,189
	2	1	,144 [*]	,011	,000	,116	,173
		3	-,075 [*]	,009	,000	-,099	-,052
	3	1	,220 [*]	,012	,000	,189	,250
		2	,075 [*]	,009	,000	,052	,099
Independiente de campo	1	2	-,178 [*]	,011	,000	-,206	-,149
		3	-,244 [*]	,012	,000	-,275	-,214
	2	1	,178 [*]	,011	,000	,149	,206
		3	-,067 [*]	,009	,000	-,090	-,043
	3	1	,244 [*]	,012	,000	,214	,275
		2	,067 [*]	,009	,000	,043	,090

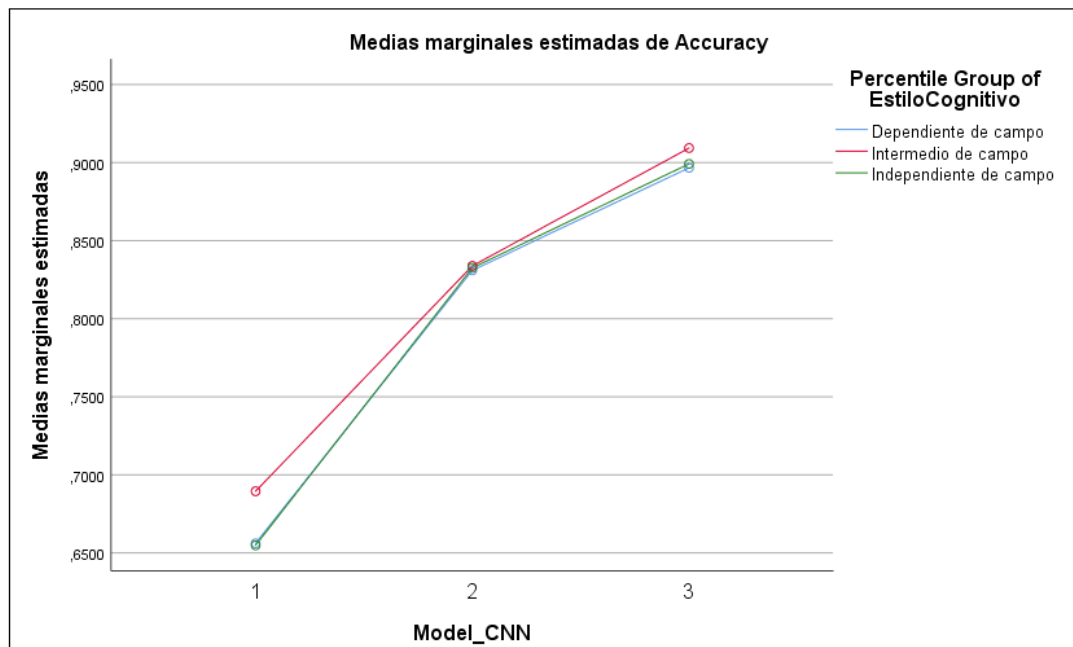
Se basa en medias marginales estimadas

*. La diferencia de medias es significativa en el nivel ,05.

b. Ajuste para varias comparaciones: Bonferroni.

Figure 5

Medidas marginales en la clasificación del entrenamiento intra-subject para los algoritmos Shallow CNN, EEGNet y CNNeeg1-1 y los estilos cognitivos en las dimensiones dependiente, intermedio e independiente de campo.



Capítulo 4. Discusiones y conclusiones

En esta investigación participaron 30 sujetos sanos (18 hombres, 12 mujeres), con edades comprendidas entre los 23 y 56 años, y un promedio de edad y desviación estándar ($M=33,72$, $SD=10,075$). Los participantes dieron su consentimiento para participar en la experimentación de captura de señales cerebrales con el fin de identificar las palabras de imaginaria del habla /abrir/, /cerrar/ y /parar/. De otro lado, se implementó el test de figuras enmascaradas para categorizar a los sujetos en la dimensiones de los estilos cognitivos como dependientes, intermedios e independientes de campo.

En este proyecto de investigación, se presenta el desarrollo de un nuevo algoritmo Deep Learning, denominado CNNeeg1-1, basado en el reconocimiento de patrones de imaginaria de palabras (/abrir/, /cerrar/, /parar/) mediante la adquisición de señales electroencefalográficas.

Los resultados mostraron, que el algoritmo propuesto CNNeeg1-1 ($M=0,8566$, $SD=0,0446$) en tareas de reconocimiento de palabras (/abrir/, /cerrar/ y /parar/) presentó un accuracy superior a investigaciones desarrollados con DL para el reconocimiento de imaginaria de palabras como: ANN presentó un accuracy de 85,20% para las palabras en inglés /yes/ y /No/ y para las palabras en hindú /Haan / y /Na/, con 5 sujetos (Balaji, et al. 2017); también, se alcanzó un accuracy con DNN de 71.8% en la clasificación de palabras cortas en inglés /in/ y /out/ y palabras largas en inglés /in/ y /cooperate/ (Panachake, et al. 2019); para el caso de Siamese Neural Network participaron 15 sujetos y se obtuvo un

accuracy de 31.40%, para la clasificación de las palabras en español /arriba/, /abajo/, /derecha/, /izquierda/, /adelante/ y /atrás/ (Lee, et al. 2020); por otro lado, para clasificar las palabras en español /arriba/, /abajo/, /derecha/, /izquierda/, /adelante/ y /atrás/, se utilizó CNN con un accuracy de 62,37%, con la participación de 15 sujetos (Cooney, et al. 2019); también, en Tamm, et al. (2020) se obtuvo un accuracy de 23.98% con CNN y la intervención de 15 sujetos para clasificar las palabras en español /arriba/, /abajo/, /derecha/, /izquierda/, /adelante/ y /atrás/. Finalmente, en la investigación de Cooney, et al. (2020) participaron 15 sujetos, para clasificar las palabras /arriba/, /abajo/, /derecha/, /izquierda/, /adelante/ y /atrás/, en donde se utilizaron los clasificadores Shallow CNN, Deep CNN y EEGNet, alcanzando una exactitud de 24.88%, 24.42% y 24.46%, respectivamente. De esta manera, y de acuerdo a lo planteado con lo anterior, se evidencia que el objetivo “Desarrollar un algoritmo de procesamiento de señales basado en Deep Learning para la clasificación de tareas de imaginería de palabras (/abrir/, /cerrar/ y /parar/) por medio de la captura de señales electroencefalográficas “, se cumplió.

En la investigación propuesta, también se determinó si existen diferencias significativas entre el algoritmo desarrollado CNNeeg1-1 y los algoritmos de referencia Shallow CNN, EEGNet utilizados en sujetos para clasificar tareas de imaginería de palabras /abrir/, /cerrar/ y /parar/. Se presentan los algoritmos de referencia junto con el algoritmo propuesto, como técnicas de clasificación de imaginería de palabras con su respectiva media y desviación estándar (ver tabla 3): Shallow CNN ($M=0.667$, $SD=0.012$) y el modelo EEGNet ($M=0.832$, $SD=0.010$), así como el algoritmo CNNeeg1-1 ($M=0.902$,

SD=0.07). De esta manera, se concluye que el modelo que presentó la media más alta es CNNeeg1-1 (M=0.902), seguido del modelo EEGNet (M=0.832).

De acuerdo al análisis realizado para la comparación entre parejas de los modelos de referencia y el desarrollado, se define que la prueba de Mauchly indicó que el supuesto de esfericidad se cumplió ($X(2) = 2.347$, $p > 0,05$) (ver tabla 4) y por consiguiente, en relación a la significancia a la hora de hacer la comparación entre parejas y cada uno de los algoritmos de referencia y el propuesto para la clasificación de imaginaria de palabras, se hizo un análisis post-hoc, basado en Bonferroni, resaltando las diferencias significativas entre parejas de variables en técnicas de clasificación (accuracy). Los resultados indicaron que hay diferencias significativas entre el modelo Shallow CNN y el modelo EEGNet de la base de datos de imaginaria de palabras ($p < 0.05$). También se tiene que hay diferencias significativas entre el modelo Shallow CNN y el modelo CNNeeg1-1 para la clasificación de imaginaria de palabras ($p < 0.05$). De igual forma, se observa que existen diferencias significativas entre el modelo EEGNet y el modelo CNNeeg1-1 ($p < 0.05$) (Ver tabla 6).

Basado en la investigación de Cooney, et al (2020) para la clasificación de imaginaria de palabras, se establece que el algoritmo propuesto CNNeeg1-1 presenta un accuracy más alto (90.2%) en comparación con los dos algoritmos de referencia Shallow CNN, EEGNet 24.88% y 24.46%, respectivamente. Con relación a la obtención de los resultados anteriores, se define que el objetivo propuesto “Identificar si existen diferencias significativas entre el algoritmo desarrollado CNNeeg1-1 y los algoritmos de referencia Shallow CNN, EEGNet utilizados en sujetos para clasificar tareas de imaginaria del habla: /abrir/, /cerrar/ y /parar/”, se cumplió.

Finalmente, se determina si existen diferencias significativas en los estilos cognitivos para sujetos clasificados en las dimensiones Dependencia, intermedio e independencia de campo a través de los clasificadores Shallow CNN, EEGNet y CNNeeg1-1 para sujetos que desarrollan tareas de imaginación del habla: /abrir/, /cerrar/ y /parar/.

En primera instancia, para determinar las dimensiones de los estilos cognitivos de cada sujeto, se aplicó el test de figuras enmascaradas (Witkin, 1954), en donde a partir de una muestra de 30 personas, se establece que 10 son dependientes de campo (1), 10 intermedios de campo (2) y 10 sujetos son independientes de campo (3) (ver tabla 6). De otra manera, se muestra una media y una desviación estándar para las tres dimensiones: dependiente de campo ($M=0.795$, $SD=0.16$), intermedio de campo ($M=0.811$, $SD=0.16$) e independiente de campo ($M=0.796$, $SD=0.16$), así, se concluye que los sujetos intermedios de campo ($M=0.811$) tiene la media más alta, seguido de los independientes de campo ($M=0.796$) y por último, los dependientes de campo ($M=0.796$).

Diversos estudios han identificado las relaciones teóricas y empíricas entre el estilo cognitivo, el aprendizaje autorregulado y el logro académico. Los resultados mostraron que hay una correspondencia sistemática entre capacidad de autorregulación y altos logros de aprendizaje en casi todos los contenidos y niveles de enseñanza. Además, existe una correlación entre algunas características estilísticas propias de los estudiantes independientes de campo y aquellos estudiantes que regulan su aprendizaje. En Camacho y Martínez (2012) se exploró el efecto diferencial de la implementación de dos métodos para la enseñanza de la escritura (silábica y global), sobre el logro de aprendizaje en niños con estilos cognitivos diferentes en la dimensión DIC, estos resultados muestran que existen

ventajas en el método global sobre el método silábico en términos generales, específicamente para los niños dependientes e intermedio de campo en seis de los ocho indicadores examinados. De igual forma, se identificaron estudios que han evaluado el rendimiento académico de los estudiantes, de acuerdo a la forma de procesar la información (Zapata 2010; Pérez, 2015). Basado en los resultados, se concluye que el objetivo planteado “Determinar si existen diferencias significativas en los estilos cognitivos para sujetos clasificados en las dimensiones Dependencia, intermedio e independencia de campo a través de los clasificadores Shallow CNN, EEGNet y CNNeeg1-1 para sujetos que desarrollan tareas de imaginación del habla: /abrir/, /cerrar/ y /parar/”, se cumplió.

Limitaciones

Es importante resaltar que debido al marco de la pandemia, esta investigación se hizo con sujetos sanos y no con sujetos con pérdida de miembro superior como se esperaba realizarlo desde un inicio, además, lo ideal hubiese sido haber realizado la experimentación con la condición mencionada y comparar los resultados entre estas dos poblaciones, de otro lado, se deseaba controlar una prótesis de miembro superior a partir de la clasificación de las señales cerebrales y por la misma situación descrita al principio, no se pudo realizar esta acción.

Recomendaciones para Futuras Investigaciones

Se sugiere que para futuras investigaciones, se logre trabajar con otras dimensiones de los estilos cognitivos con el fin de identificar si existen diferencias significativas en relación a tareas de imaginería del habla, ya que en esta investigación no hubo. Por otro lado, se busca el poder controlar una prótesis de miembro superior con personas amputadas en esta extremidad. De otro modo, lo ideal sería aumentar el número de la muestra para que los resultados de las dimensiones DIC de los estilos cognitivos difiera entre ellos y no se obtenga una muestra tan homogénea como la resultante.

Referencias

- Amezcu-Aguilar, T., & Amezcu-Aguilar, P. (2018). Contextos inclusivos: el reconocimiento de la lengua de signos como derecho de las personas con diversidad funcional.
- Ashok Muzumdar, Ed., *Powered Upper Limb Protheses*. OttawaCanada: Springer-Verlag Berlin Heidelberg, 2004.
- Bakardjian, H., Tanaka, T., & Cichocki, A. (2010). Optimization of SSVEP brain responses with application to eight-command brain-computer interface. *Neuroscience letters*, 469(1), 34-38.

- Balaji, A., Haldar, A., Patil, K., Ruthvik, T. S., Valliappan, C. A., Jartarkar, M., & Baths, V. (2017, July). EEG-based classification of bilingual unspoken speech using ANN. In *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 1022-1025). IEEE.
- Bengio, Y., Goodfellow, I., & Courville, A. (2017). *Deep learning* (Vol. 1). Massachusetts, USA: MIT press.
- Bera, T. K. Brain Computer Interfaces: Current Trends and Applications.
- Camacho, L. J. R., & Martínez, C. H. (2012). Escritura inicial y estilo cognitivo. *Folios*, (35), 49-65.
- Chen, Q., Li, Y., & Yuan, X. (2021). A hybrid method for muscle artifact removal from EEG signals. *Journal of Neuroscience Methods*, 353, 109104.
- Cooney, C., Korik, A., Folli, R., & Coyle, D. (2020). Evaluation of Hyperparameter Optimization in Machine and Deep Learning Methods for Decoding Imagined Speech EEG. *Sensors*, 20(16), 4629.
- Cooney, C., Korik, A., Raffaella, F., & Coyle, D. (2019, September). Classification of imagined spoken word-pairs using convolutional neural networks. In *The 8th Graz BCI Conference, 2019* (pp. 338-343). Verlag der Technischen Universitat Graz.
- Coretto, G. A. P., Gareis, I. E., & Rufiner, H. L. (2017, January). Open access database of EEG signals recorded during imagined speech. In *12th International Symposium on*

Medical Information Processing and Analysis (Vol. 10160, p. 1016002).

International Society for Optics and Photonics.

Desrosiers-Sabbath, R. (1993). *L'Enseignement et L'Hémisphère Cérébral Droit*. Quebec: Ed. Presses de L'Université du Quebec.

Edelman, B. J., Baxter, B., & He, B. (2015). EEG source imaging enhances the decoding of complex right-hand motor imagery tasks. *IEEE Transactions on Biomedical Engineering*, 63(1), 4-14.

El Imrani, N. (2018). Una revisión de la neuroanatomía y neurofisiología del lenguaje. *Revista de Neuro-Psiquiatría*, 81(3), 196-202.

Farina, D., Jiang, N., Rehbaum, H., Holobar, A., Graimann, B., Dietl, H., & Aszmann, O. C. (2014). The extraction of neural information from the surface EMG for the control of upper-limb prostheses: emerging avenues and challenges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4), 797-809.

Fujimaki, N., Takeuchi, F., Kobayashi, T., Kuriki, S., & Hasuo, S. (1994). Event-related potentials in silent speech. *Brain topography*, 6(4), 259-267.

García, M. A., & Galán, Y. I. J. (2009). Diagnóstico de los estilos de aprendizaje en los estudiantes: Estrategia docente para elevar la calidad educativa. *CPU-e, Revista de Investigación educativa*, (9), 1-21.

- García-Salinas, J. S., Villaseñor-Pineda, L., Reyes-García, C. A., & Torres-García, A. A. (2019). Transfer learning in imagined speech EEG-based BCIs. *Biomedical Signal Processing and Control*, 50, 151-157.
- Ghosh, R., Sinha, N., Biswas, S. K., & Phadikar, S. (2019). A modified grey wolf optimization based feature selection method from EEG for silent speech classification. *Journal of Information and Optimization Sciences*, 40(8), 1639-1652.
- González, R., & Hornauer-Hughes, A. (2014). Cerebro y lenguaje. *Revista Hospital Clínico Universidad de Chile*, 25(1), 144-153.
- González-Castañeda, E. F., Torres-García, A. A., Reyes-García, C. A., & Villaseñor-Pineda, L. (2017). Sonification and textification: Proposing methods for classifying unspoken words from EEG signals. *Biomedical Signal Processing and Control*, 37, 82-91.
- Graimann, B., Allison, B. Z., & Pfurtscheller, G. (Eds.). (2010). *Brain-computer interfaces: Revolutionizing human-computer interaction*. Springer Science & Business Media.
- Hashim, N., Ali, A., & Mohd-Isa, W. N. (2017, November). Word-based classification of imagined speech using EEG. In *International Conference on Computational Science and Technology* (pp. 195-204). Springer, Singapore.
- Hassanien, A. E., & Azar, A. A. (2015). *Brain-computer interfaces. Switzerland: Springer*.

- Heilmeyer, F. A., Schirrmeister, R. T., Fiederer, L. D., Völker, M., Behncke, J., & Ball, T. (2018). A framework for large-scale evaluation of deep learning for EEG. In *IEEE International Conference on Systems, Man, and Cybernetics (SMC)*.
- Herrera, L. (2019). Procesamiento Cerebral del Lenguaje: Historia y evolución teórica. *Fides et Ratio-Revista de Difusión cultural y científica de la Universidad La Salle en Bolivia*, 17(17), 101-130.
- Ito, N., Ono, N., Vincent, E., & Sagayama, S. (2010, March). Designing the Wiener post-filter for diffuse noise suppression using imaginary parts of inter-channel cross-spectra. In *2010 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 2818-2821). IEEE.
- Jingwei, L., Yin, C., & Weidong, Z. (2015, July). Deep learning EEG response representation for brain computer interface. In *2015 34th Chinese Control Conference (CCC)* (pp. 3518-3523). IEEE.
- Kaongoen, N., & Jo, S. (2017). A novel hybrid auditory BCI paradigm combining ASSR and P300. *Journal of neuroscience methods*, 279, 44-51.
- Lee, D. Y., Lee, M., & Lee, S. W. (2020, October). Classification of Imagined Speech Using Siamese Neural Network. In *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 2979-2984). IEEE.

- Li, G., Lee, C. H., Jung, J. J., Youn, Y. C., & Camacho, D. (2020). Deep learning for EEG data analytics: A survey. *Concurrency and Computation: Practice and Experience*, 32(18), e5199.
- López-Vargas, O., Hederich-Martínez, C., & Camargo-Uribe, Á. (2011). Estilo cognitivo y logro académico. *Educación y educadores*, 14(1).
- Martin, S., Brunner, P., Holdgraf, C., Heinze, H. J., Crone, N. E., Rieger, J., ... & Pasley, B. N. (2014). Decoding spectrotemporal features of overt and covert speech from the human cortex. *Frontiers in neuroengineering*, 7, 14.
- Martin, S., Brunner, P., Iturrate, I., Millán, J. D. R., Schalk, G., Knight, R. T., & Pasley, B. N. (2016). Word pair classification during imagined speech using direct brain recordings. *Scientific reports*, 6, 25803.
- Martin, S., Brunner, P., Iturrate, I., Millán, J. D. R., Schalk, G., Knight, R. T., & Pasley, B. N. (2017). Corrigendum: Word pair classification during imagined speech using direct brain recordings. *Scientific reports*, 7.
- Mathew, A., Amudha, P., & Sivakumari, S. (2020, February). Deep Learning Techniques: An Overview. In *International Conference on Advanced Machine Learning Technologies and Applications* (pp. 599-608). Springer, Singapore.
- Moctezuma, L. A., & Molinas Cabrera, M. M. (2018). Towards an API for EEG-based imagined speech classification. In *ITISE 2018-International Conference on Time Series and Forecasting*.

- Moctezuma, L. A., Torres-García, A. A., Villaseñor-Pineda, L., & Carrillo, M. (2019). Subjects identification using EEG-recorded imagined speech. *Expert Systems with Applications, 118*, 201-208.
- Mohammad, A., Siddiqui, F., & Alam, M. A. (2021, January). Feature Extraction from EEG Signals: A deep learning perspective. In *2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence)* (pp. 757-760). IEEE.
- Muñoz González, J. M., Gutiérrez-Arenas, M. P., & Serrano Rodríguez, R. (2012). Los hemisferios cerebrales: dos estilos de pensar, dos modos de enseñar y aprender.
- Nguyen, C. H., Karavas, G. K., & Artemiadis, P. (2017). Inferring imagined speech using EEG signals: a new approach using Riemannian manifold features. *Journal of neural engineering, 15*(1), 016002.
- Panachakel, J. T., Ramakrishnan, A. G., & Ananthapadmanabha, T. V. (2020). A novel deep learning architecture for decoding imagined speech from eeg. *arXiv preprint arXiv:2003.09374*.
- Portellano Pérez, J. (1992). *Introducción al estudio de las asimetrías cerebrales*. Madrid: Colección Neurociencia Ciencias de la Educación Preescolar y Especial.
- Qureshi, M. N. I., Min, B., Park, H. J., Cho, D., Choi, W., & Lee, B. (2017). Multiclass classification of word imagination speech with hybrid connectivity features. *IEEE Transactions on Biomedical Engineering, 65*(10), 2168-2177.

- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T. H., & Faubert, J. (2019). Deep learning-based electroencephalography analysis: a systematic review. *Journal of neural engineering*, *16*(5), 051001.
- Salama Salama, M., ElSherif, L., Lashin, H., & Gamal, T. (2014). Recognition of unspoken words using electrode electroencephalographic signals. In *The Sixth International Conference on Advanced Cognitive Technologies and Applications* (pp. 51-5)
- Sarmiento Vela, L. C. (2019). *Interfaces cerebro-computador para el reconocimiento automático del habla silenciosa*. Universidad Pedagógica Nacional.
- Stern, J. M. (2005). *Atlas of EEG patterns*. Lippincott Williams & Wilkins.
- Tamm, M. O., Muhammad, Y., & Muhammad, N. (2020). Classification of Vowels from Imagined Speech with Convolutional Neural Networks. *Computers*, *9*(2), 46.
- Tong, S., & Thakor, N. V. (2009). *Quantitative EEG analysis methods and clinical applications*. Artech House.
- Torres-García, A. A., Reyes-García, C. A., Villaseñor-Pineda, L., & Ramírez-Cortés, J. M. (2013). Electroencephalographic Signals Analysis for Imagined Speech Classification. *Revista Mexicana de Ingeniería Biomédica*, *34*(1), 23-39.
- Uva, A. (2017). Neurociencias en el ámbito educativo. Estilos cognitivos y estrategias de aprendizaje. *Revista Internacional Magisterio*, *68*.

Villamizar, S. I., Sarmiento, L. C., López, O., Caballero, J., & Bacca, J. (2019, November).

EEG Vowel Silent Speech Signal Discrimination Based on APIT-EMD and SVD.

In *International Conference on Advanced Engineering Theory and*

Applications (pp. 74-83). Springer, Cham.

Wang, L., Zhang, X., Zhong, X., & Zhang, Y. (2013). Analysis and classification of

speech imagery EEG for BCI. *Biomedical signal processing and control*, 8(6), 901-

908.