

Intérprete de señales cerebrales con aprendizaje profundo para el control de Servomotores

M. en I.S.C. Leonardo M. Moreno Villalva*, Dr. Adolfo Meléndez Ramírez*, y
Dr. Francisco Jacob Ávila Camacho*



Acerca de los autores...

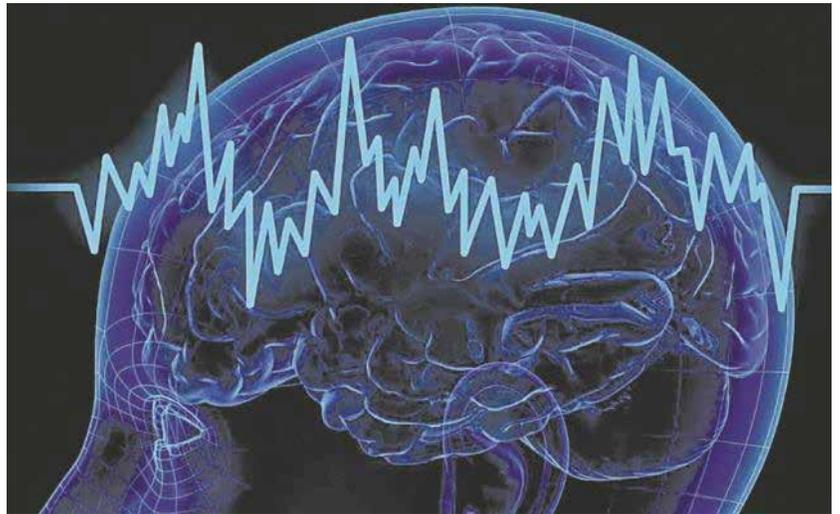
*Docente de la División de Ingeniería
Informática del Tecnológico de Estudios
Superiores de Ecatepec.

Resumen

Actualmente en todo el mundo según cifras de la Organización Mundial de la Salud (OMS) al menos 500,000 personas sufren lesiones medulares cada año. Esas personas tienen una probabilidad entre dos y cinco veces mayor de morir

prematuramente, siendo los países de ingresos bajos y medios los que registran las peores tasas de supervivencia. (Organización Nacional de la Salud, 2014)

A nivel global el tema de las personas con discapacidad motriz ha sido de gran importancia, esto derivado del aumento en las cifras de quienes padecen esta condición. Por tal motivo, se ha visto la necesidad de buscar nuevos métodos y técnicas que permitan crear un sistema que facilite al usuario métodos, herramientas y técnicas que le brinden una mayor independencia y capacidad para desenvolverse en la vida cotidiana y laboral. Una de las herramientas y métodos que pueden ser usados, son las concernientes a la inteligencia artificial, la cual, mediante el aprendizaje profundo, nos puede proporcionar una nueva forma de otorgar los medios a las personas con alguna discapacidad motriz para poder desenvolverse libremente en su ambiente laboral y social.



El presente artículo tiene por objeto mostrar el proceso de construcción de un sistema que permita manipular la movilidad de un modelo de desplazamiento, a través de una conexión inalámbrica, que en este caso será implementada por un módulo Bluetooth, el cual controlará el funcionamiento de los motores de una silla de ruedas mediante comandos recibidos por un sistema BCI (Brain Computer Interfaces). (Organización Nacional de la Salud, 2014)

Palabras clave: Inteligencia Artificial, EEG, BCI Red Neuronal

Abstract

Currently worldwide, according to World Health Organization (WHO) figures, at least 500,000 people suffer from spinal cord injuries each year. These people are two to five times more likely to die prematurely, with low-and middle-income countries registering the worst survival rates. (National Health Organization, 2014)

At the global level the issue of people with motor disabilities has been of great importance, this is derived from the increase in the numbers of those who suffer from this condition. For this reason, we have seen the need to seek new methods and techniques to create a system that provides the user with methods, tools and techniques that provide greater independence and ability to cope in everyday life and work. One of the tools and methods that can be used, are those concerning artificial intelligence, which, through deep learning, can provide us with a new way of giving the media to people with a motor impairment in order to develop freely in their work and social environment.

The purpose of this article is to show the process of building a system that allows to manipulate the mobility of a displacement model, through a wireless connection, which in this case will be implemented by a Bluetooth module, which controls the Operation of the motors of a wheelchair by means of commands received by a BCI (Brain Computer Interfaces) system.

Keywords: Artificial intelligence, EEG, BCI neural network.

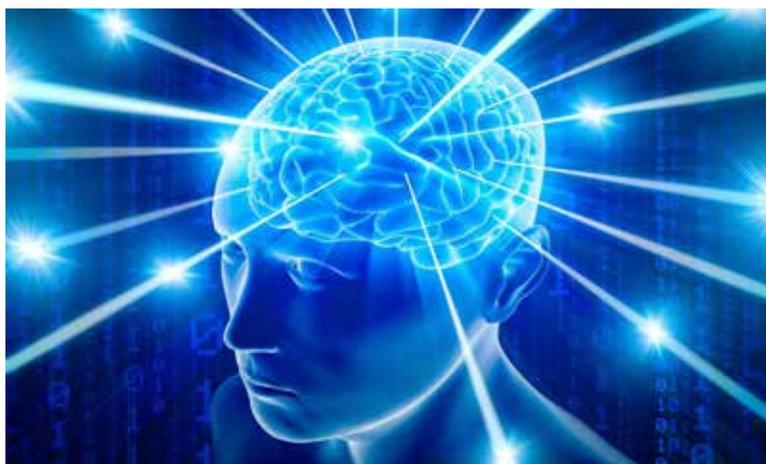
Introducción

Dentro de los limitantes que más a menudo se presentan para las personas con discapacidad o que se encuentran en silla de ruedas, es la dependencia para movilidad, es decir su falta de libertad individual. Al respecto, las cifras que presenta la OMS es que año con año va en aumento el número de personas con discapacidad motriz. Para el caso de México, la prevalencia en el 2014 fue de 6%, según los datos de la Encuesta Nacional de la Dinámica Demográfica (ENADID) 2014. (INEGI, 2014). Esto significa que 7.1 millones de habitantes del país presenta alguna discapacidad. Aunado a ello un efecto que se deriva de este problema, es el bajo desarrollo humano para una vida independiente. Esta situación, se traduce en una dependencia hacia los núcleos familiares de las personas con discapacidad, lo que finalmente crea barreras físicas, sociales y económicas que les excluyen de una sociedad igualitaria. (SEDESOL, 2016).

Es a partir de esta problemática, que surge la idea para que mediante la utilización e implementación de diferentes modelos y algoritmos de inteligencia artificial, que pueden ser aplicados al concepto de la análisis e interpretación de señales como los son modelos de regresión, clasificación, clustering, modelos de series de tiempo, y modelos de Machine Learning, es factible realizar una correcta interpretación

de señales cerebrales que pueden ser traducidas en órdenes para el control diferentes dispositivos móviles. Los modelos de Machine Learning incluyen elementos que van desde el los modelos de Support Vector Machine (SVN), Sistemas Difusos de Redes Neuronales, así como también Redes Neuronales Artificiales. Si bien todos estos modelos han sido utilizados para modelar, analizar y tratar de interpretar las señales cerebrales, en México no se ha producido ningún modelo o sistemas que lo permita.

En este artículo, se describe un sistema de análisis e interpretación de señales cerebrales para su traducción específica en comandos operativos mediante interfaces cerebro-computadora, monitores de análisis de señales cerebrales y aprendizaje profundo.



Antecedentes

Imaginemos poder controlar un robot u otra máquina usando solo nuestros pensamientos: esta noción fantástica hace tiempo que ha capturado la imaginación de la sociedad y, dentro de la última década, la capacidad de eludir los canales de comunicación convencionales entre el cerebro de un usuario y una computadora se ha convertido en una realidad demostrada. Las interfaces de la computadora cerebral monitorean la actividad cerebral del usuario y permiten traducir sus pensamientos en comandos sin activar ningún músculo o nervio periférico.

Al respecto, han surgido diferentes investigaciones derivadas de la necesidad que implica el análisis e interpretación de señales cerebrales, el trabajo desarrollado por Ewan S. Nurse, Philippa J. Karoly, and David B. Grayden. (2015), en el cual describe un método generalizado para clasificar las señales neuronales relacionadas con el motor para una interfaz cerebro-computadora (BCI), basado en un método de aprendizaje automático estocástico, siendo un ejemplo base para la aplicación y creación de un modelo aplicativo.

Una investigación que vale la pena resaltar es la realizada por John Thomas y colaboradores (2017) en la cual se ofrece una comparación de varios algoritmos de

clasificación tradicionales en contraste con los métodos más nuevos de aprendizaje profundo. Explora dos tipos diferentes de métodos de aprendizaje profundo, redes neuronales convolucionales (CNN) y redes neuronales recurrentes (RNN) con arquitectura de memoria a corto plazo (LSTM).

La investigación desarrollada por Shifei Ding y colaboradores (2015) presenta un modelo llamado máquina de aprendizaje extremo profundo (DELM) y la aplica a la clasificación EEG, mediante máquinas de aprendizaje extremo multicapa (MLELM) y máquinas de aprendizaje extremo con núcleo (KELM).

Un trabajo de investigación un poco más general es el desarrollado por Sarah N. Abdulkader, Ayman Atia, and Mostafa-Sami M. Mostafa (2015), en el cual se proporciona más información sobre las funciones de BCI y las aplicaciones asociadas, explorando varios métodos para adquirir señales cerebrales, así como los problemas que enfrentan los sistemas BCI y algunas soluciones encontradas a sus consecuencias.

Dentro del área de extracción y clasificación, los autores Noman Naseer and Keum-Shik Hong (2015) revisan las tareas de generación de señales cerebrales, los métodos de eliminación de ruido, los esquemas de extracción/selección de características, y las técnicas de clasificación para BCI basado en la técnica fNIRS, siendo un ejemplo base para la construcción del modelo de extracción de datos.

Exclusivamente para el área de clasificación de señales mediante inteligencia artificial, Yu Zhang y colaboradores (2016) presentan una introducción a un método bayesiano escaso, mediante la explotación de las técnicas de Laplace, nombrado, SBLaplace, para la clasificación EEG.

Como puede verse, a través de la medición, el análisis, y la clasificación de señales cerebrales, es posible generar nuevas áreas de conocimiento y oportunidad para el control de diferentes elementos, que poder ir desde el control básico de servomotores hasta el control de prótesis y manipulación remota de robots mediante EEG, proporcionando una área de conocimiento que puede ser integrada y aplicada en diferentes ámbitos de la industria.

En este trabajo se desarrollará un sistema de adquisición, análisis, y clasificación de señales cerebrales Deep Learning (Aprendizaje Profundo) para el control de servomotores y su interpretación en comandos específicos; la etapa de adquisición de datos será implementada con una plataforma ARM (Advanced RISC Machine) de bajo costo (Arduino), que realizará un pre-procesamiento de las señales adquiridas de la red de sensores EEG y una red neuronal multicapa, capaz de identificar contaminantes ambientales automáticamente.

La red neuronal se emplea para identificar la señal cerebral pensada. En el sistema de cómputo, se utiliza para el proceso de entrenamiento. Una vez que la red neuronal es entrenada, la operación consiste en propagar los datos a través de la red con una carga computacional mucho menor, la cual consiste principalmente en una multiplicación vector-matriz y una búsqueda en tablas que lleva a cabo la función de activación para identificar rápidamente el comando.

Marco teórico

La constante evolución tecnológica ha comenzado a hacer realidad todas esas ficciones que algún día observábamos en películas o libros futuristas acerca de la inteligencia artificial, como lo refiere el autor John Haugeland (1988). “La inteligencia artificial no es descabellada ni inevitable” (Haugeland, 1988) y cada día nos acercamos más a esta realidad tecnológica.

Podemos encontrar múltiples definiciones acerca el tema de inteligencia artificial e incluso podemos llegar a creer que no existe una definición exacta y pueden crearse controversias sobre el concepto de inteligencia, como bien lo expresa Alberto García: “Se dice que los humanos son una especie inteligente: saben hablar, resuelven problemas matemáticos, han llegado a la Luna... pero ¿acaso no son inteligentes el resto de los animales que habitan en el planeta? En efecto, un perro muestra comportamientos inteligentes, incluso es capaz de expresar sentimientos. ¿Dónde poner el límite de lo que es o no es inteligente entonces?” (García, 2012)

Sin embargo, Virgini Mathevet. (2018) menciona que para Alan Turing existen ciertas pruebas que permiten determinar si se puede considerar que un programa es, o no inteligente. “El test de Turing consiste en realizar una comunicación entre un ser humano encargado de realizar la prueba con dos pantallas. Detrás de la otra pantalla tenemos el programa que queremos comprobar. Se solicita, pasada una fase en la que el encargado de realizar la prueba discute con ambos sistemas, determinar cuál era el ser humano. Si no se es capaz de diferenciar a la máquina del ser humano, entonces se ha superado la prueba” (Mathevet, 2018, p. 4)

Según Mathivet: (2018), el dominio de la inteligencia artificial es muy basto y permite cubrir numerosas técnicas diferentes. La capacidad de cálculo cada vez mayor de los ordenadores, una mejor comprensión de ciertos procesos de naturaleza vinculados a la inteligencia y el progreso de los investigadores en las ciencias fundamentales han permitido realizar grandes avances.

La inteligencia artificial, en la interpretación de John Searle, es que el “objetivo sería la construcción de artefactos con prestaciones que ayudan o asisten al hombre en la resolución de tareas teóricas o prácticas de diferente complejidad” (Sebastian, Puerto, 2004).

La inteligencia artificial ha ido evolucionando desde sus orígenes, concepto que está basado en máquinas y ordenadores, de acuerdo con Marco Casella (2004) “La evolución de la inteligencia artificial (IA) tiene una historia reciente y una fecha oficial de nacimiento, con la cual la comunidad científica está de acuerdo: 1956. En esta perspectiva, la Inteligencia Artificial se considera el punto de llegada de un proceso evolutivo que ha permitido extender la automatización desde algunas actividades de trabajo manual al trabajo intelectual, por ejemplo la elaboración de cálculos complicados, el control y la planificación, la consultoría especializada en algunas áreas” (Casella, 2004).

Los ANS, por su acrónimo en inglés que significa Artificial Neural System o Redes Neuronales: RN, son modelos matemáticos que nos ayudan a formular teorías sobre el funcionamiento del cerebro humano. Como nos explica el autor Redondo Fonseca (2016), los ANS también hacen referencia a las redes neuronales artificiales, neuro-computadoras y procesadores de distribución paralela (Rendón, 2016).

En el lapso de las últimas décadas, han surgido diversos modelos de redes neuronales propuestas por estudios acerca de las redes neuronales. Como señalan Juan Ramírez y Mario Chacón



(2011), los ANS también hacen referencia a las redes neuronales artificiales, neuro-computadoras y procesadores de distribución paralela. Asimismo mencionan que en el lapso de las últimas décadas, han surgido diversos modelos de redes neuronales propuestas por estudios acerca de las redes neuronales, “las técnicas para analizar una imagen digital se agrupan en un área llamada Procesamiento Digital de Imágenes” (Ramírez y Chacón, 2011).



Las características básicas del deep learning, como lo explican Yoshua Bengio Goodfellow y Aaron Courville, en su libro *Deep Learning*, (2016) “se genera a través de algoritmos, la capacidad que tiene hiperparámetros y la validación de las estadísticas; son conjuntos de instrucciones que analizan estas herramientas y las técnicas que extraen variables de un estudio realmente útil y válido para un ámbito determinado (Goodfellow, 2016)

Las aplicaciones del deep learning en la informática son variadas, ya que le permiten a una computadora percibir o visualizar el entorno que le rodea al igual como lo hacemos los seres humanos. Así, como lo cita el libro *Deep learning for computer vision* de Rajalingappaa: “Una computadora puede estar en forma de Smartphone, drones, CCTV, scanner MRI, entre otros con varios sensores para percibir. El sensor produce imágenes de manera digital, las cuales pueden ser interpretadas por la computadora (Rajalingappaa, 2018), su definición es explicar detalladamente la optimización de la misma.

Debido a que las imágenes percibidas por un ordenador pueden venir de diversas fuentes, es posible clasificar cómo es que son percibidas. La primera aplicación del deep learning, puede ser para la clasificación de las imágenes. “La clasificación de imágenes es la tarea de etiquetar la imagen completa como si se tratase de un objeto o concepto”, también puede servir como la detección o localización y segmentación “es la tarea que consiste en encontrar un objeto en una imagen y encasillarlo”. El deep learning a su vez, puede ser usado para diferenciación de objetos dentro de las imágenes “basado en el significado semántico” (Rajalingappaa, 2018).

Las aplicaciones más populares del deep learning a nivel comercial, mencionadas por el autor Vishnu Subramanian (2018), nos dice que son las clasificaciones de imágenes, reconocimiento de voz, traducción máquina, automóviles autónomos, asistentes como Siri o Alexa, detección de cáncer, traducción de lenguajes a nivel humano.

Hablar de deep learning es hablar de redes neuronales que tuvieron su inspiración en el trabajo ganador del premio nobel de Hubel y Wiesel, en la corteza visual primaria de los gatos. (Hubel & Wiesel, 1962).

Los experimentos mostraron que las redes neuronales estaban organizadas en capas jerárquicas de células para procesar el estímulo visual. El primer modelo matemático de una red neuronal, denominado Neocognitron, en 1980 por Fukushima, tenía muchas de las características de las redes neuronales profundas (DNN) de hoy día, que típicamente están entre 7 y 10 capas, pero más recientemente se han escalado a cientos de capas para ciertas aplicaciones.

Ray Kurzweil, inventor estadounidense y científico especializado en Ciencias de la Computación e Inteligencia Artificial, es desde el 2012 director de Ingeniería en Google, pero antes de serlo, se reunió con el CEO de dicha multinacional; él no buscaba trabajo, sino comenzar su empresa, en la cual desarrollaría sus ideas sobre cómo construir una computadora inteligente capaz de entender el lenguaje, así como hacer inferencias y tomar decisiones por sí misma.

Kurzweil se sintió atraído por los avances de Google en una tecnología llamada Deep Learning, el software que intenta imitar a un cerebro, el software que aprende, en un sentido muy real, a reconocer patrones a partir de representaciones digitales de sonidos, imágenes y otros datos. “La idea principal de este software es que pueda simular gran parte de las neuronas en una red neuronal artificial”. (Robert D. Hof, 2014).

Anteriormente, un sistema de aprendizaje profundo de Google “al que se le habían mostrado 10 millones de imágenes de videos de You Tube, demostró casi el doble que cualquier esfuerzo previo de reconocimiento de imágenes para identificar objetos como los gatos”. (Hof, 2014).

Desarrollo

Se recopiló información sobre las señales cerebrales que el dispositivo MindWave es capaz de detectar, como ya anteriormente se mencionó; asimismo, se realizaron algunas pruebas con la diadema y el uso de la aplicación NeuroSky BrainWave, la cual nos muestra cómo MindWave detecta las ondas cerebrales y los parámetros en que los está midiendo, como se muestra en la siguiente imagen.

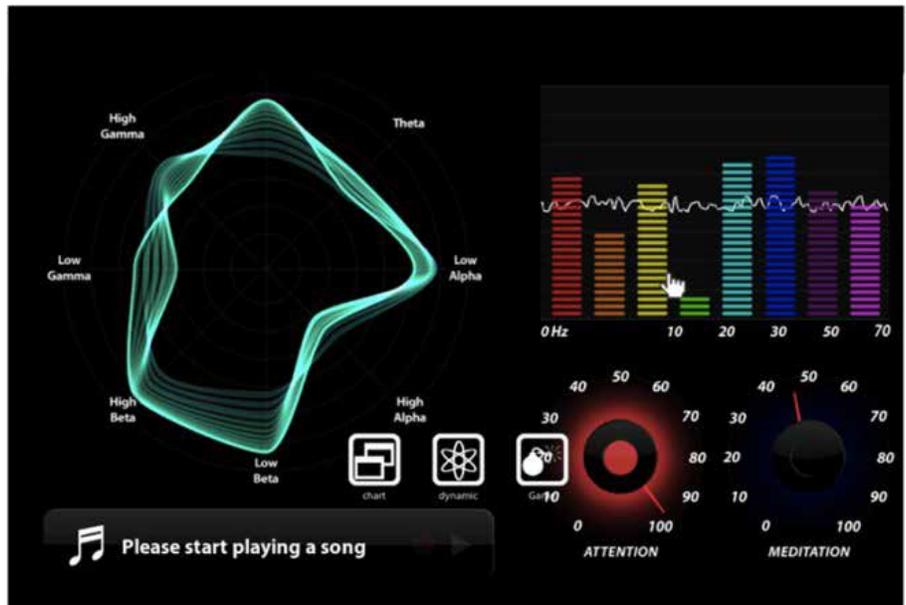


Figura 1

Prueba con aplicación BranWave

La codificación de una aplicación se realizó en Android Studios, la cual serviría de interprete entre la placa de Arduino UNO y la diadema MindWave, es decir, los datos que recibieran los sensores de la diadema MindWave serían enviados a esta aplicación para poder traducirlos mediante el uso de una librería proporcionada por NeuroSky a fin de detectar los parpadeos y los niveles de atención y meditación del usuario.

A continuación, se muestra parte de la codificación correspondiente a la aplicación antes mencionada.

```

433 @Override
434 public void onRecordFail(int flag) {
435     log.e(TAG, "onRecordFail: " + flag);
436 }
437
438 @Override
439 public void onChecksumFail(byte[] payload, int length, int checksum) {
440 }
441
442 @Override
443 public void onDataReceived(int datatype, int data, Object obj) {
444     switch (datatype) {
445         case HindDataType.CODE_ATTENTION:
446             short attvalue[] = ((short)data);
447             nskAlgoSdk.nskAlgoDataStream(nskAlgoDataType.NSK_ALGO_DATA_TYPE_ATT.value, attvalue, 1);
448             break;
449         case HindDataType.CODE_MEDITATION:
450             short medvalue[] = ((short)data);
451             nskAlgoSdk.nskAlgoDataStream(nskAlgoDataType.NSK_ALGO_DATA_TYPE_MED.value, medvalue, 1);
452             break;
453         case HindDataType.CODE_POOR_SIGNAL:
454             short pqvalue[] = ((short)data);
455             nskAlgoSdk.nskAlgoDataStream(nskAlgoDataType.NSK_ALGO_DATA_TYPE_PQ.value, pqvalue, 1);
456             //sample.setText(String.valueOf(pqvalue));
457             break;
458         case HindDataType.CODE_RAW:
459             raw_data[raw_data_index++] = (short)data;
460             if (raw_data_index == 812) {
461                 nskAlgoSdk.nskAlgoDataStream(nskAlgoDataType.NSK_ALGO_DATA_TYPE_RAW.value, raw_data, raw_data_index);
462                 raw_data_index = 0;
463             }
464             break;
465         default:
466             break;
467     }
468 }
469
470 public void showToast(final String msg, final int timeStyle) {
471     MainActivity.this.runOnUiThread(new Runnable() {
472         public void run() {
473             Toast.makeText(getApplicationContext(), msg, timeStyle).show();
474         }
475     });
476 }
477 }

```

Figura 2

Codificación de reconocimiento de imágenes para identificar objetos (Hof, 2014).

Posteriormente se realizó una pequeña codificación en Arduino, donde se estarían recibiendo las órdenes mediante la aplicación para poder mover los motores, como se observa en la siguiente ilustración.

```

int Motor_A_Enable = 9;
int Motor_A_Reverse = 4;
int Motor_A_Forward = 3;
int Motor_B_Enable = 10;
int Motor_B_Reverse = 7;
int Motor_B_Forward = 12;

void setup() {
    Serial.begin(9600);
    pinMode(Motor_A_Enable, OUTPUT);
    pinMode(Motor_A_Forward, OUTPUT);
    pinMode(Motor_A_Reverse, OUTPUT);
    pinMode(Motor_B_Enable, OUTPUT);
    pinMode(Motor_B_Forward, OUTPUT);
    pinMode(Motor_B_Reverse, OUTPUT);
}

void loop() {
    if(Serial.available() > 0) {
        char data;
        data = Serial.read();
        Serial.write(Serial.read());

        switch (data) {
            case '4': //FORWARD
                digitalWrite(Motor_A_Reverse, LOW);
                digitalWrite(Motor_B_Reverse, LOW);
                digitalWrite(Motor_A_Forward, HIGH);
                digitalWrite(Motor_B_Forward, HIGH);
                for(int a = 0; a < 200; a++) {
                    analogWrite(Motor_B_Enable, a);
                    analogWrite(Motor_A_Enable, a);
                    Serial.println("adelante ");
                    delay(5);
                } break;

            case '5': //REVERSE
                digitalWrite(Motor_A_Forward, LOW);
                digitalWrite(Motor_B_Forward, LOW);
                digitalWrite(Motor_A_Reverse, HIGH);
                digitalWrite(Motor_B_Reverse, HIGH);
                for(int a = 0; a < 200; a++) {
                    analogWrite(Motor_B_Enable, a);
                    analogWrite(Motor_A_Enable, a);
                    Serial.println("reversa ");
                    delay(5);
                } break;

            case '7': //FORWARD LEFT
                digitalWrite(Motor_A_Forward, HIGH);
                digitalWrite(Motor_A_Reverse, LOW);
                for(int a = 0; a < 255; a++) {
                    analogWrite(Motor_A_Enable, a);
                    analogWrite(Motor_B_Enable, a);
                    delay(5);
                }
                analogWrite(Motor_A_Enable, 230);
                Serial.println("izquierda ");
                break;

            case '6': //FORWARD RIGHT
                digitalWrite(Motor_B_Forward, HIGH);
                digitalWrite(Motor_B_Reverse, LOW);
                analogWrite(Motor_B_Enable, 230);
                Serial.println("derecha ");
                break;

            default: //If bluetooth module receives any
                //value not listed above, motors turn off
                analogWrite(Motor_A_Enable, 0);
                analogWrite(Motor_B_Enable, 0);
                Serial.println("alto ");
        }
    }
}

```



Diseño y construcción de prototipo de pruebas

Se realizó el diseño y construcción de un prototipo con motores, empleando el material proporcionado por el laboratorio, éste se adaptó de manera que tuviera el espacio suficiente para las conexiones del material electrónico y el soporte para el peso del mismo, con el propósito de implementar la codificación requerida.

El material utilizado para el prototipo es el que se muestra en la siguiente tabla.

TABLA 1
RECURSOS MATERIALES PARA EL MONTAJE DEL PROTOTIPO

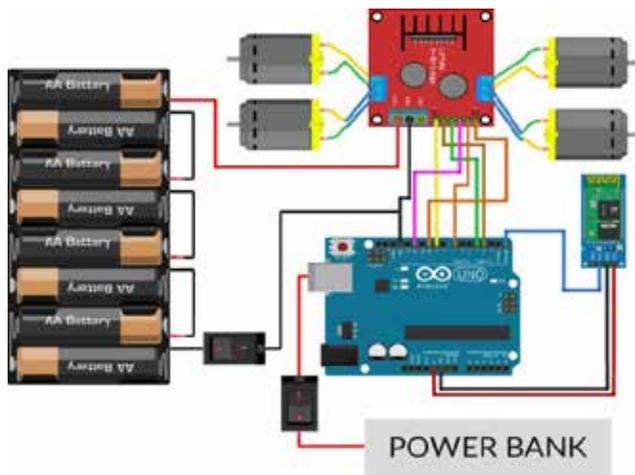
C.	DESCRIPCIÓN
1	Neurosky Mindwave Mobile Brainwave
1	Arduino Uno
1	Módulo Bluetooth HC-05
1	Puente H
4	Motor educutores
4	Ruedas para Carro
1	Chasis de Acrilico
2	Porta pilas
8	Baterías AA
40	Jumpers



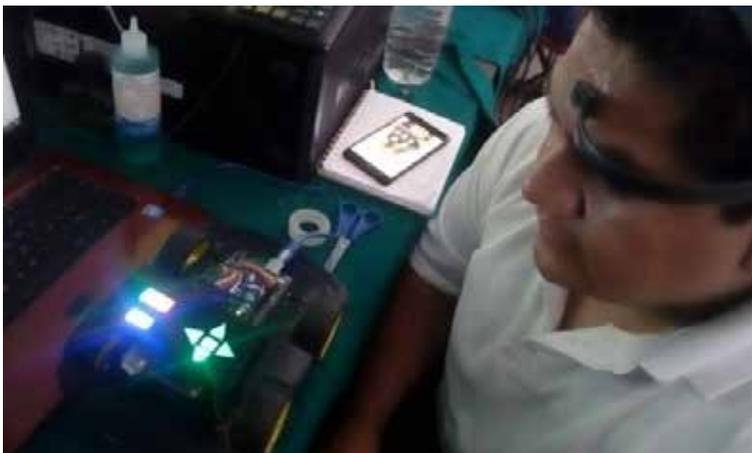
Figura 2

Diagrama de conexión de placa Arduino y demás componentes en el Chasis Prototipo

Se configuró el módulo de bluetooth y la diadema MindWave de manera que exista una intercomunicación directa que permita la recolección de datos EEG; asimismo, se realizó la conexión de la placa Arduino con el puente H y los motorreductores.



Con esta codificación se puso en funcionamiento el prototipo, moviendo la dirección con los parpadeos forzados; si el nivel de atención es alto, entonces se encenderán los motores, de lo contrario, los motores permanecerán apagados hasta que el usuario se concentre.



Conclusiones

Con el análisis de las señales cerebrales obtenido a lo largo del proyecto, se puede concluir que es posible implementar un control a diversos dispositivos electrónicos a través de una interfaz y sensores que se pueden calibrar, esto con el propósito de cubrir necesidades que pueden ir desde una incapacidad motriz y poder dar más opciones a personas con capacidades diferentes, hasta poder automatizar un inmueble.

Al ser una tecnología relativamente nueva, hay una gran posibilidad de innovar con un buen trabajo de investigación y análisis, con el cual se abren posibilidades hasta de lograr un dispositivo autónomo.

Se recomienda que al hacer uso del prototipo y la interfaz, se recolecten todos los datos posibles de las lecturas de los sensores, puesto que con ello se puede hacer una mejora importante, aplicando Machine Learning.

Por otro lado, es importante considerar que al ser un sensor analógico, se busca tener más exactitud al momento de procesar las señales obtenidas, porque se sabe que ninguna persona tiene un comportamiento idéntico a otro, incluso en humor o estado anímico, pues es posible que a lo largo del día experimentemos distintas reacciones a situaciones diferentes. Por este motivo se recomienda tener escenarios controlados para así, contar con una base de datos cada vez mejor, que nos permita ser más exactos.

Referencias

Casella, M. (2004). Historia y Evolución de La Inteligencia Artificial. Recuperado de https://books.google.com.mx/books/about/Historia_y_evolución_de_la_Inteligencia.html?id=rv3BBwAAQBAJ&source=kp_cover&redir_esc=y

Ewan, S. *et al.* (June 26, 2015). A Generalizable Brain-Computer Interface (BCI) Using Machine Learning for Feature Discovery. Investigation article. EBSCOhost, " PLOS ONE.15. doi. org/10.1371/journal.pone.0131328

García, A. (2012). *Inteligencia Artificial : Fundamentos, Práctica y Aplicaciones*. 2ª. Edición. Madrid, España: RC Libros.

Goodfellow, *et al.* (2016). *Deep Learning*, ICML2013 Tutorial, 2011, doi:10.1038/nmeth.3707.

Haugeland, J. (1988). *Inteligencia Artificial*. México: Siglo XXI.

Hof, Robert D. (2014). Deep Learning - MIT Technology Review. Recuperado de <https://www.technologyreview.com/s/513696/deep-learning/>.

INEGI, Instituto Nacional de Estadística y Geografía.(2014). La Discapacidad en México. DOI:362.4021.

John, T. *et al.* (2017). Deep Learning-Based Classification for Brain-Computer Interfaces Advanced Multi-Sensor Anomaly Monitoring and Analytics for Gas Pipeline View Project

Meta-Learning View Project Deep Learning-Based Classification for Brain-Computer Interfaces. doi:10.1109/SMC.2017.8122608.

Mathevet, V. (2018). *Inteligencia Artificial, para desarrolladores, conceptos e implementación C#*. 2ª Edición. Barcelona: Ediciones Software.

Noman, N. and Keum-S. H. (January 28, 2015). FNIRS-Based Brain-Computer Interfaces: A Review. *Frontiers in Human Neuroscience* 9 3. doi:10.3389/fnhum.2015.00003

OMS, Organización Mundial de la Salud, The International Spinal Cord Society. (2014). *Discapacidades y rehabilitación. Lesiones de la médula espinal: perspectivas internacionales*. OMS WHO/NMH/VIP1303. Recuperado de https://www.who.int/disabilities/publications/spinal_cord_injuries/

Puerto, A.S. (2004). Historia y Evolución de la Inteligencia Artificial, Recuperado de <http://es.calameo.com/read/00287981054d48962be99>.

Rajalingappaa, S. (2018) Deep Learning for Computer Vision Expert Techniques to Train Advanced Neural Networks Using TensorFlow and Keras.

Ramírez, J. and Chacón, M.(2011). *Redes Neuronales Artificiales Para El Procesamiento de Imágenes, una revisión de la última década artificial neural Networks for Image Processing, a Review of the Last Decade*" 9, no. 1. Recuperado de <https://www.itson.mx/publicaciones/rieeyc/>

Documents/v9/art2vf_redes_neuronales_artificiales_para_el_procesamiento_de_imagenes-una_revisión_de_la_última_decada.pdf

Redondo Fonseca, M. (2016). Simulación de redes neuronales como herramienta Big Data en el ámbito sanitario. España, Lulu.com. 2016.

Sarah, N. *et al.* (July 1, 2015) Brain Computer Interfacing: Applications and Challenges, *Egyptian Informatics Journal* 16, no. 2: 213–30. doi:10.1016/J.EIJ.2015.06.002

SEDESOL, Secretaría de Desarrollo Social. (2016). Diagnóstico sobre la situación de las personas con discapacidad en México. Recuperado de https://www.gob.mx/cms/uploads/attachment/file/126572/Diagnostico_sobre_la_Situación_de_las_Personas_Con_Discapacidad_Mayo_2016.pdf

Shifei D., *et al.* (May 27, 2015). Deep Extreme Learning Machine and Its Application in EEG Classification. *Mathematical Problems in Engineering* 2015: 1–11. doi 10.1155/2015/129021

Subramanian, V. (2018). Deep Learning with Pytorch: A Practical Approach to Building Neural Network Models Using Pytorch.

Yu Zhang, *et al.* (November 2016). Sparse Bayesian Classification of EEG for Brain-Computer Interface. *IEEE Transactions on Neural Networks and Learning Systems* 27, No. 11. 2256–67, doi:10.1109/TNNLS.2015.2476656.