



**UNIVERSIDAD AUTÓNOMA
DE AGUASCALIENTES**

**CENTRO DE CIENCIAS BÁSICAS
DEPARTAMENTO DE CIENCIAS DE LA COMPUTACIÓN**

TESIS

**ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUEDA DE PATRONES DE
APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES MEDIANTE
MINERÍA DE DATOS.**

PRESENTA

Eduardo Emmanuel Rodríguez López

**PARA OBTENER EL GRADO DE MAESTRO EN CIENCIAS CON OPCIÓN A
COMPUTACIÓN**

TUTORES

Dr. Francisco Javier Álvarez Rodríguez

Dr. Miguel Vargas Martín

INTEGRANTES DEL COMITÉ TUTORAL

Dr. Julio Cesar Ponce Gallegos

Dr. Luis Daniel Cuellar Garrido

Aguascalientes, Ags, 10 de febrero de 2020



Mtro. José de Jesús Ruíz Gallegos
DECANO (A) DEL CENTRO DE CIENCIAS BÁSICAS

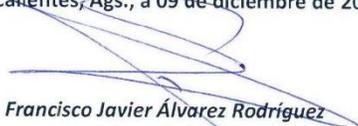
PRESENTE

Por medio del presente como **TUTOR** designado del estudiante **EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ** con ID **179552** quien realizó *la tesis* titulada: **ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUEDA DE PATRONES DE APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES MEDIANTE MINERÍA DE DATOS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que **él** pueda proceder a imprimirla así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"

Aguascalientes, Ags., a 09 de diciembre de 2019.



Francisco Javier Álvarez Rodríguez
Tutor de tesis

El nombre completo que aparece en el Voto Aprobatorio debe coincidir con el que aparece en el documento empastado. No se puede abreviar, ni omitir nombres

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión de Calidad.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 01
Emisión: 17/05/19



Mtro. José de Jesús Ruíz Gallegos
DECANO (A) DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **CO-TUTOR** designado del estudiante **EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ** con ID **179552** quien realizó *la tesis* titulada: **ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUEDA DE PATRONES DE APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES MEDIANTE MINERÍA DE DATOS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que *él* pueda proceder a imprimirla así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"
Aguascalientes, Ags., a 09 de diciembre de 2019.

A handwritten signature in black ink, appearing to read 'Miguel VM'.

Miguel Vargas Martin
Co-tutor de tesis

El nombre completo que aparece en el Voto Aprobatorio debe coincidir con el que aparece en el documento empastado. No se puede abreviar, ni omitir nombres

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión de Calidad.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 01
Emisión: 17/05/19



Mtro. José de Jesús Ruíz Gallegos
DECANO (A) DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **ASESOR** designado del estudiante **EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ** con ID **179552** quien realizó *la tesis* titulada: **ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUEDA DE PATRONES DE APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES MEDIANTE MINERÍA DE DATOS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que *él* pueda proceder a imprimirla así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE
"Se Lumen Proferre"

Aguascalientes, Ags., a 09 de diciembre de 2019.

Julio Cesar Ponce Gallegos
Asesor de tesis

El nombre completo que aparece en el Voto Aprobatorio debe coincidir con el que aparece en el documento empastado. No se puede abreviar, ni omitir nombres

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión de Calidad.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 01
Emisión: 17/05/19

INDIVIDUAL



Mtro. José de Jesús Ruíz Gallegos
DECANO (A) DEL CENTRO DE CIENCIAS BÁSICAS

PRESENTE

Por medio del presente como **ASESOR** designado del estudiante **EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ** con ID **179552** quien realizó *la tesis* titulada: **ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUEDA DE PATRONES DE APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES MEDIANTE MINERÍA DE DATOS**, un trabajo propio, innovador, relevante e inédito y con fundamento en el Artículo 175, Apartado II del Reglamento General de Docencia doy mi consentimiento de que la versión final del documento ha sido revisada y las correcciones se han incorporado apropiadamente, por lo que me permito emitir el **VOTO APROBATORIO**, para que *él* pueda proceder a imprimirla así como continuar con el procedimiento administrativo para la obtención del grado.

Pongo lo anterior a su digna consideración y sin otro particular por el momento, me permito enviarle un cordial saludo.

ATENTAMENTE

"Se Lumen Proferre"

Aguascalientes, Ags., a 09 de diciembre de 2019.

Luis Daniel Cuéllar Garrido
Asesor de tesis

El nombre completo que aparece en el Voto Aprobatorio debe coincidir con el que aparece en el documento empastado. No se puede abreviar, ni omitir nombres

c.c.p.- Interesado
c.c.p.- Secretaría Técnica del Programa de Posgrado

Elaborado por: Depto. Apoyo al Posgrado.
Revisado por: Depto. Control Escolar/Depto. Gestión de Calidad.
Aprobado por: Depto. Control Escolar/ Depto. Apoyo al Posgrado.

Código: DO-SEE-FO-07
Actualización: 01
Emisión: 17/05/19



DICTAMEN DE LIBERACIÓN ACADÉMICA PARA INICIAR LOS TRÁMITES DEL EXAMEN DE GRADO



Fecha de dictaminación dd/mm/aa: 20/01/2020

NOMBRE: EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ ID 179552

PROGRAMA: Maestría en Ciencias en Computación, Matemáticas Aplicadas LGAC (del posgrado): Computación (Ingeniería de Software)

TIPO DE TRABAJO: (X) Tesis () Trabajo práctico

TÍTULO: Análisis de señales EEG para la búsqueda de patrones de aprendizaje de personas con ceguera normovisuales mediante Minería de Datos

IMPACTO SOCIAL (señalar el impacto logrado): Inclusión de personas con discapacidad visual

INDICAR SI/NO SEGÚN CORRESPONDA:

Elementos para la revisión académica del trabajo de tesis o trabajo práctico:

- El trabajo es congruente con las LGAC del programa de posgrado
La problemática fue abordada desde un enfoque multidisciplinario
Existe coherencia, continuidad y orden lógico del tema central con cada apartado
Los resultados del trabajo dan respuesta a las preguntas de investigación o a la problemática que aborda
Los resultados presentados en el trabajo son de gran relevancia científica, tecnológica o profesional según el área
El trabajo demuestra más de una aportación original al conocimiento de su área
Las aportaciones responden a los problemas prioritarios del país
Generó transferencia del conocimiento o tecnológica

El egresado cumple con lo siguiente:

- Cumple con lo señalado por el Reglamento General de Docencia
Cumple con los requisitos señalados en el plan de estudios (créditos curriculares, optativos, actividades complementarias, estancia, predoctoral, etc)
Cuenta con los votos aprobatorios del comité tutorial, en caso de los posgrados profesionales si tiene solo tutor podrá liberar solo el tutor
Cuenta con la carta de satisfacción del Usuario
Coincide con el título y objetivo registrado
Tiene congruencia con cuerpos académicos
Tiene el CVU del Conacyt actualizado
Tiene el artículo aceptado o publicado y cumple con los requisitos institucionales (en caso que proceda)

En caso de Tesis por artículos científicos publicados:

- Aceptación o Publicación de los artículos según el nivel del programa
El estudiante es el primer autor
El autor de correspondencia es el Tutor del Núcleo Académico Básico
En los artículos se ven reflejados los objetivos de la tesis, ya que son producto de este trabajo de investigación.
Los artículos integran los capítulos de la tesis y se presentan en el idioma en que fueron publicados
La aceptación o publicación de los artículos en revistas indexadas de alto impacto

Con base a estos criterios, se autoriza se continúen con los trámites de titulación y programación del examen de grado

Sí
No

FIRMAS

Elaboró:

* NOMBRE Y FIRMA DEL CONSEJERO SEGÚN LA LGAC DE ADSCRIPCIÓN:

DR. FRANCISCO JAVIER ÁLVAREZ RODRÍGUEZ

NOMBRE Y FIRMA DEL SECRETARIO TÉCNICO:

DR. HERMILDO SÁNCHEZ CRUZ

* En caso de conflicto de intereses, firmará un revisor miembro del NAB de la LGAC correspondiente distinto al tutor o miembro del comité tutorial, asignado por el Decano.

Revisó:

NOMBRE Y FIRMA DEL SECRETARIO DE INVESTIGACIÓN Y POSGRADO:

DRA. HAYDEE MARTÍNEZ RUVALCABA

Autorizó:

NOMBRE Y FIRMA DEL DECANO:

M. en C. JORGE MARTÍN ALFEREZ CHÁVEZ

Nota: procede el trámite para el Depto. de Apoyo al Posgrado

Elaborado por: D. Apoyo al Posg.
Revisado por: D. Control Escolar/D. Gestión de Calidad.
Aprobado por: D. Control Escolar/ D. Apoyo al Posg.

Código: DO-SEE-FO-15
Actualización: 01
Emisión: 20/06/19

Agradecimientos

El esfuerzo y la dedicación siempre tienen sus frutos, pero no saben igual sin compartirlos con aquellos que te brindaron apoyo y guía durante un proceso de paciencia, tropiezos y correcciones que siempre son para bien.

Por ello, para la escritura de mi tesis y en general de todo mi trabajo de investigación, agradezco profundamente al CONACyT por haberme brindado la oportunidad de cursar mis estudios de maestría con una beca nacional. Así mismo, me gustaría también mencionar a mi Alma Mater, la Universidad Autónoma de Aguascalientes, mi segunda casa, institución que a través del programa de la Maestría en Ciencias en Computación, Matemáticas Aplicadas, en conjunto con el Instituto de la Sociedad del Conocimiento del Estado de Aguascalientes y el Municipio de Aguascalientes, ayudaron a financiar parte de la estancia de investigación realizada a finales del año pasado e inicios del presente a la ciudad de Oshawa, Canadá.

Así mismo, estoy agradecido también con mi universidad receptora en el extranjero, el Ontario Tech, en el cual no recibí más que un cálido y excelente trato durante toda mi estancia.

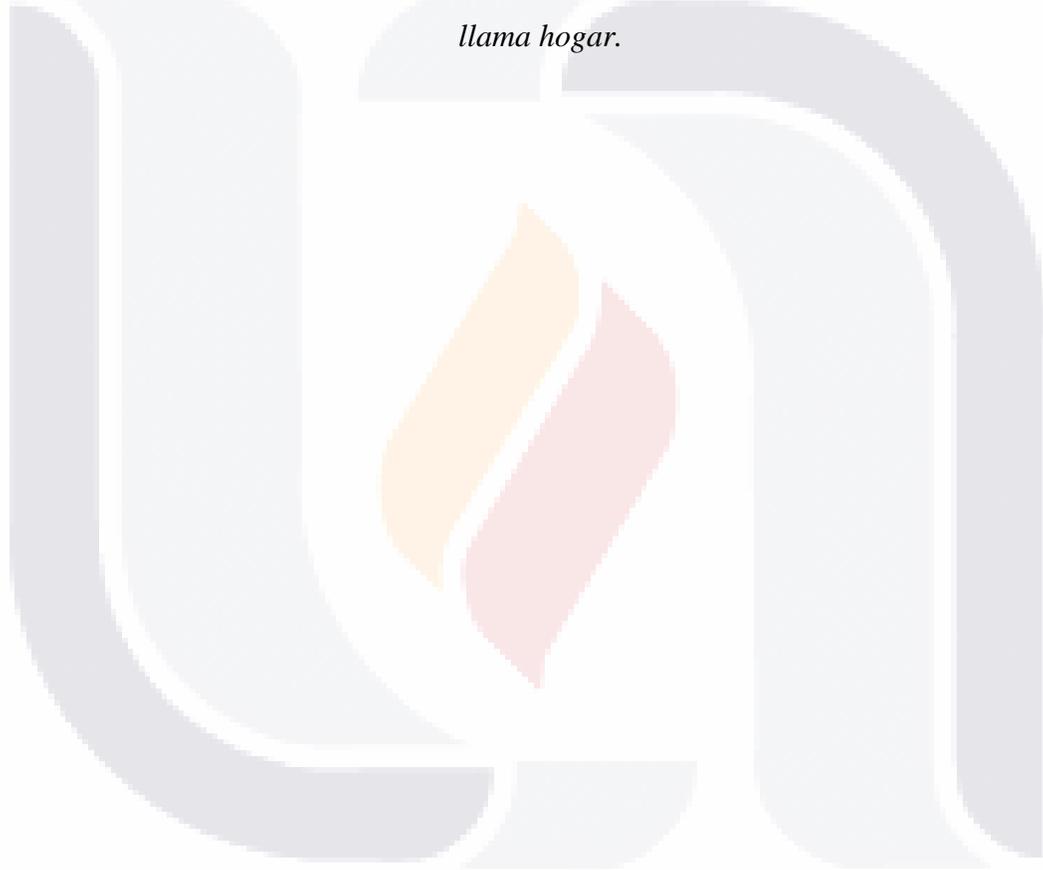
Referente a lo académico, agradezco a mis profesores, en particular a los miembros de mi comité tutorial: al Dr. Francisco Álvarez por su gran confianza depositada en mi trabajo, por su guía, sus comentarios, correcciones y sus charlas; Al Dr. Miguel Vargas, por su recibimiento y guía durante los meses en que realicé la estancia en Canadá, por sus comentarios, su cordialidad, por haberme mostrado un área tan interesante que desconocía hasta ese momento (*Machine Learning*) y por abrirme las puertas de su casa; A los Doctores Julio Ponce y Luis Cuéllar por haberme mantenido al tanto en el gusto por el análisis de datos, los algoritmos y sus siempre acertadas correcciones a mi trabajo, así como el apoyo técnico que me brindaron.

Por último, a Dios, a mi esposa y mi hijo, a mi familia en general, por haber estado conmigo en cada momento y apoyarme en cualquier circunstancia. Por sus consejos y guía durante toda mi vida.

Dedicatoria

Para mi esposa, la persona más importante en mi vida.

No imagino haber hecho esto sin tu ayuda, sin tus ganas y tu impulso. Me has acompañado desde el inicio, y si bien, no siempre es fácil, me seguiste desde el calor hasta el frío, porque no importa donde estemos, siempre que estemos juntos, a eso se le llama hogar.



Índice General

Acrónimos.....	7
Resumen	8
Abstract.....	9
Introducción.....	10
Capítulo I: Formulación de la Investigación.....	12
1.1 Antecedentes.....	12
2.1 Problemática de la Investigación.....	18
1.3 Preguntas de Investigación.....	19
1.3.1 Pregunta general.....	19
1.3.2 Preguntas específicas.....	19
1.4 Objetivos de Investigación.....	20
1.4.1 Objetivo general.....	20
1.4.2 Objetivos específicos.....	20
1.5 Justificación.....	21
Capítulo II: Marco Teórico.....	22
2.1 Electroencefalografía.....	22
2.1.1 Artefactos.....	25
2.1.2 Interpretación del EEG.....	25
2.1.3 Registro de actividad en el EEG.....	26
2.1.4 Tipos de Montajes.....	27
2.1.5 Características de la actividad cerebral.....	28
2.2 Aprendizaje y memoria.....	31
2.3 Ceguera.....	36
2.4 <i>Machine Learning</i> (Aprendizaje Automático).....	37
2.5 Minería de Datos.....	38
2.6 Sistemas Clasificadores.....	39
2.6.1 Diseño de un algoritmo de clasificación.....	40
2.6.2 Proceso de clasificación.....	41
2.7 Ganancia de Información (<i>InfoGain</i>).....	43
2.7.1 Ejemplo aplicado a un pequeño <i>Dataset</i>	44
Capítulo III: Método de Investigación.....	51
3.1 Planeación.....	51
3.1.1 Metodologías de base y apoyo.....	51
3.1.2 Videos de divulgación científica como actividad de aprendizaje.....	53
3.1.3 Cuestionarios.....	53

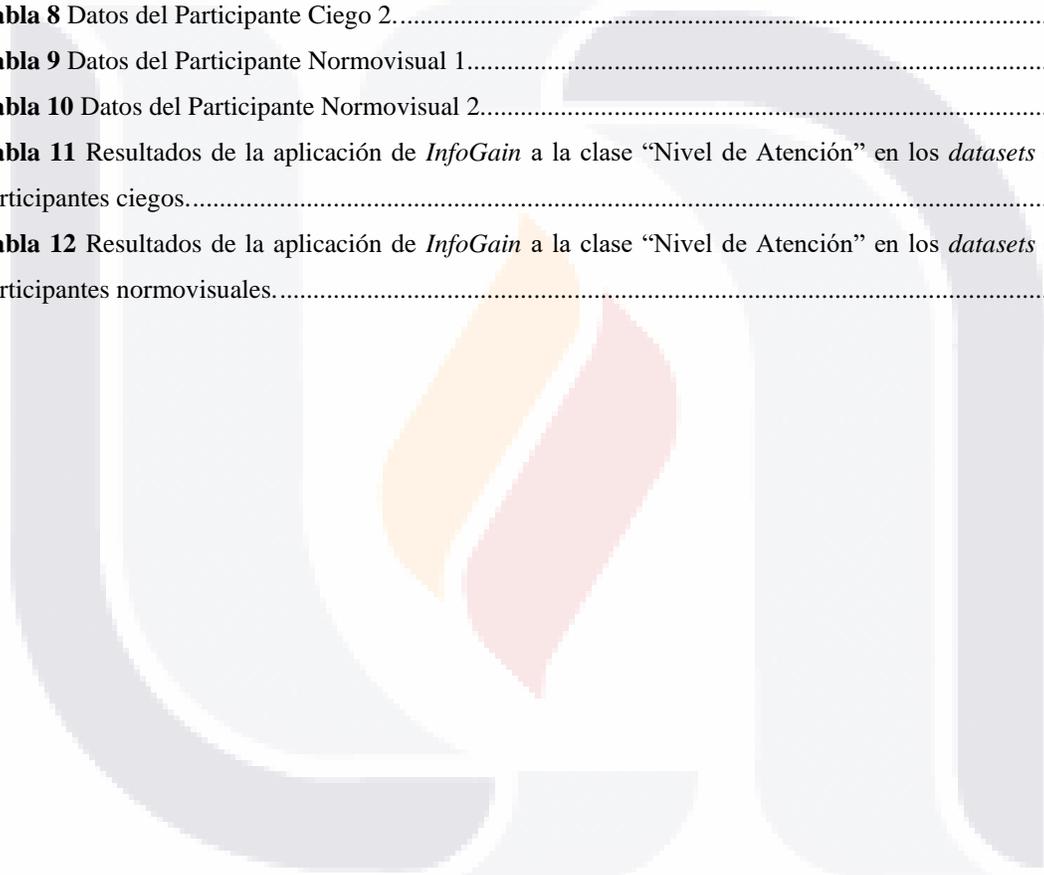
3.1.4 Detección y trabajo con participantes.....	54
3.2 Ejecución.....	54
3.2.1 <i>Hardware</i> utilizado.....	54
3.2.2 <i>Software</i> para la adquisición.....	55
3.2.3 Análisis en <i>WEKA</i>	57
3.2.4 Entorno del experimento.....	58
3.2.5 Desarrollo del experimento.....	58
3.3 Comparación con los casos de estudio.....	59
Capítulo IV: Resultados.....	61
4.1 Histogramas de Atención y Datos de los participantes.....	61
4.1.1 Participantes ciegos.....	61
4.1.2 Participantes Normovisuales.....	62
4.2 Gráficas de Atención.....	64
4.2.1 Participantes ciegos.....	64
4.2.2 Participantes normovisuales.....	65
4.3 Relación del Nivel de Atención con los niveles <i>Low Beta</i> y <i>High Beta</i> de cada participante.....	66
4.3.1 Participantes ciegos.....	66
4.3.2 Participantes normovisuales.....	68
4.4 Aplicación de Ganancia de Información (<i>InfoGain</i>).....	70
Discusión de Resultados.....	72
Interpretación de los Histogramas y las Tablas de Datos de los participantes.....	72
Interpretación de las gráficas de Atención de los participantes.....	72
Participante ciego 1.....	72
Participante ciego 2.....	72
Participante normovisual 1.....	73
Participante normovisual 2.....	73
Aplicación del algoritmo de análisis <i>InfoGain</i>	73
Interpretación de la relación de las ondas <i>Low Beta</i> y <i>High Beta</i> con el Nivel de Atención.....	73
Comparación con los casos de estudio.....	74
Experimento 1 vs Estudio Actual.....	74
Experimento 2 vs Estudio Actual.....	75
Conclusiones.....	76
6.1 Pregunta General:.....	76
6.2 Preguntas específicas.....	76
6.3 Objetivo general.....	78
6.4 Objetivos específicos.....	78
6.5 Comparación con los casos de estudio.....	80
6.6 Aportaciones de la Investigación.....	80

6.7 Trabajo Futuro	81
6.8 Productos generados	81
Referencias.	82
Anexos	85



Índice de Tablas

Tabla 1 Resultados sobre la predicción de jugar o no jugar tenis.	44
Tabla 2 Datos utilizados para el cálculo de la Entropía.	46
Tabla 3 Datos utilizados para el cálculo del <i>InfoGain</i> de <i>Humidity</i>	47
Tabla 4 Datos para el cálculo de H_L	48
Tabla 5 Datos para el cálculo de H_R	49
Tabla 6 Atributos y su descripción del <i>DataSet</i>	57
Tabla 7 Datos del Participante Ciego 1.	61
Tabla 8 Datos del Participante Ciego 2.	62
Tabla 9 Datos del Participante Normovisual 1.	62
Tabla 10 Datos del Participante Normovisual 2.	63
Tabla 11 Resultados de la aplicación de <i>InfoGain</i> a la clase “Nivel de Atención” en los <i>datasets</i> de los participantes ciegos.	70
Tabla 12 Resultados de la aplicación de <i>InfoGain</i> a la clase “Nivel de Atención” en los <i>datasets</i> de los participantes normovisuales.	71



Índice de Figuras

Figura 1 Sistema propuesto por los autores en el artículo "Initial Analysis of Brain EEG Signal for Mental State Detection of Human Being"(Kimmatkar & Babu, 2017). 12

Figura 2 Framework propuesto para la clasificación de estados mentales (Subhani et al., 2017). . 15

Figura 3 Canales utilizados para el registro EEG en el artículo anteriormente mencionado (Jasper, 1958). 16

Figura 4 El sistema internacional 10-20 de localización de electrodos. A, oreja; C, central; F, frontal; Fp, frontal polar; P, parietal; Pg, nasofaríngeo; T, temporal; O, occipital. El lado derecho se registra con números pares y el lado izquierdo con números nones y en la línea media con Z (Aminoff, 2012). 23

Figura 5 Artefacto surgiendo en electrodo T5. B, artefacto electromiográfico en la región temporal izquierda. C, artefacto de masticación. D, artefacto electrocardiográfico (Aminoff, 2012). 25

Figura 6 Ritmo alfa normal 9-10 Hz registrado en el EEG de un hombre de 64 años. Se puede ver la distribución posterior y respuesta del ritmo al abrir los ojos (Aminoff, 2012). 29

Figura 7 Descarga de espigas interictal surgiendo en la región central independiente de cualquier hemisferio en un paciente con convulsiones desde la infancia (Aminoff, 2012). 30

Figura 8 Sistema de memoria descubierto en el caracol *Aplysia* (Hall, 2017). 34

Figura 9 Activaciones funcionales de regiones prefrontal y medial temporal donde fueron predictivos del rendimiento de la memoria posterior. Se presentaron palabras simples, seguidas de una instrucción para recordar u olvidar. 35

Figura 10 Esquema para la generación de conocimiento en bases de datos KDD (Braga et al., 2009). 39

Figura 11 A la izquierda, una galaxia espiral, a la derecha, una galaxia elíptica. 40

Figura 12 Aproximación para la construcción de un algoritmo de clasificación (Tan, 2018). 41

Figura 13 Proceso de clasificación (Cuéllar, 2018). 42

Figura 14 Errores en clasificación (Cuéllar, 2018). 42

Figura 15 Ejemplo de clasificación (Cuéllar, 2018). 43

Figura 16 Árbol de Decisión generado a partir de la aplicación de *InfoGain*. 50

Figura 17 Etapas del Método de Investigación. 51

Figura 18 *Headset MindWave Mobile* de *NeuroSky* (NeuroSky, 2015b). 55

Figura 19 Arquitectura de procesamiento y registro de señales EEG. 56

Figura 20 Fases de la Experimentación 59

Figura 21 Histograma de Atención del Participante Ciego 1. 61

Figura 22 Histograma de Atención del Participante Ciego 2. 62

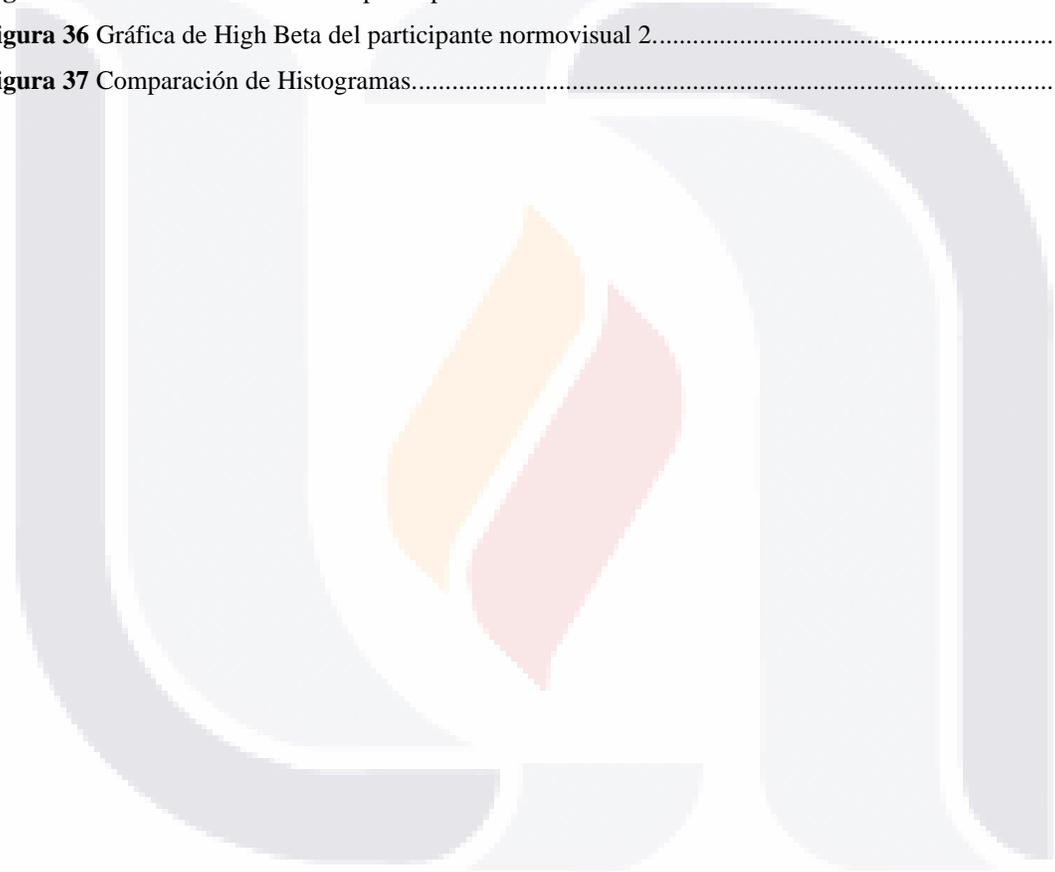
Figura 23 Histograma de Atención del Participante Normovisual 1. 63

Figura 24 Histograma de Atención del Participante Normovisual 2. 63

Figura 25 Gráfica de Atención del participante ciego 1. 64

Figura 26 Gráfica de Atención del participante ciego 2. 65

Figura 27 Gráfica de Atención del participante normovisual 1. 65
Figura 28 Gráfica de Atención del participante normovisual 2. 66
Figura 29 Gráfica de *Low Beta* del participante ciego 1..... 67
Figura 30 Gráfica de *High Beta* del participante ciego 1..... 67
Figura 31 Gráfica de *Low Beta* del participante ciego 2..... 68
Figura 32 Gráfica de *High Beta* del participante ciego 2..... 68
Figura 33 Gráfica de *Low Beta* del participante normovisual 1. 69
Figura 34 Gráfica de *High Beta* del participante normovisual 1..... 69
Figura 35 Gráfica de *Low Beta* del participante normovisual 2. 70
Figura 36 Gráfica de *High Beta* del participante normovisual 2..... 70
Figura 37 Comparación de Histogramas..... 74



Acrónimos

EEG: Electroencefalograma.

ML: *Machine Learning*.

MD: Minería de Datos.

CSV: *Comma-Separated Values*.

WEKA: *Waikato Environment for Knowledge Analysis*.



Resumen

En la presente investigación se realiza una comparación de los niveles de atención entre participantes ciegos y normovisuales durante una tarea enfocada al aprendizaje, que consta de observar un video de divulgación científica y la posterior resolución de un breve cuestionario enfocado al video. El estudio está centrado en el análisis de las señales electroencefalográficas, adquiridas a partir del *headset MindWave Mobile*, mediante la implementación de un algoritmo de *Machine Learning* (utilizado en Minería de Datos) llamado *Information Gain (InfoGain)*, que mide el grado en que un atributo “aporta información” a la clase. Los atributos que conforman el *dataset* son el tiempo, la época, las potencias y las señales de las ondas cerebrales *Delta, Theta, Low Alpha, High Alpha, Low Beta, High Beta, Low Gamma y Mid Gamma*, las señales *Meditation, Attention* y la señal EEG en crudo. La clase “Nivel de Atención” se formó a partir de *Attention*, dividiendo el rango de la señal (0-100) en cinco, considerándose de 0-20 “Muy Mala”, 21-40 “Mala”, 41-60 “Regular”, 61--80 “Buena” y 81-100 “Muy Buena”. La experimentación se efectuó con cinco participantes ciegos y diez normovisuales, quienes eligieron el video de divulgación científica de su preferencia y a la postre contestaron el cuestionario. Después de un análisis estadístico se encontró que el Nivel de Atención promedio en ambos grupos tuvo una diferencia de diez puntos aproximadamente, 41.0804 para ciegos, 51.7644 para normovisuales, mientras que, en conjunto, el de ambos grupos fue 46.4224. cayendo en la categoría de Atención “Regular”. En cuanto a los resultados obtenidos con la aplicación de *InfoGain*, ambos grupos presentaron las mismas ondas con mayor incidencia en el Nivel de Atención: *Delta, Theta y Attention*, a excepción de la presencia de *High Beta* también en los participantes normovisuales.

Palabras clave: *EEG, Information Gain, Machine Learning, Minería de Datos.*

Abstract

In the current research, a comparison of the levels of attention between blind and normovisual participants is made during a task focused on learning, which consists of observing a scientific dissemination video and the subsequent resolution of a brief test focused on the video. The study focuses on the analysis of electroencephalographic signals, acquired from the MindWave Mobile headset, through the implementation of a Machine Learning algorithm (used in Data Mining) called Information Gain (InfoGain), which measures the degree to which an attribute "provides information" to the class. The attributes that make up the dataset are time, epoch, power and signals of the brain waves Delta, Theta, Low Alpha, High Alpha, Low Beta, High Beta, Low Gamma and Mid Gamma, Meditation, Attention and EEG signal in raw. The class "Attention Level" was formed from Attention, dividing the signal range (0-100) in five, considering 0-20 "Very Bad", 21-40 "Bad", 41-60 "Regular", 61-80 "Good" and 81-100 "Very Good". The experimentation was carried out with five blind and ten normovisual participants, who chose the scientific dissemination video of their preference and at the end answered the test. After a statistical analysis it was found that the average Level of Attention in both groups had a difference of approximately ten points, 41.0804 for the blind, 51.7644 for normovisuals, while, together, that of both groups was 46.4224. falling into the category of "Regular" Attention. As for the results obtained with the application of InfoGain, both groups presented the same waves with greater incidence in the Level of Attention: Delta, Theta and Attention, except for the presence of High Beta also in the normovisual participants.

Key Words: EEG, Information Gain, Machine Learning, Data Mining.

Introducción.

Hoy en día, los avances en los estudios de electroencefalografía permiten identificar y generar nuevo conocimiento sobre cómo los humanos pensamos desde un análisis sustentado en la fisiología.

Un electroencefalograma (EEG) es el registro, mediante electrodos en el cuero cabelludo, de las corrientes eléctricas ocasionadas por los potenciales sinápticos producidos en los cuerpos celulares y las dendritas de la corteza cerebral (Fox, 2014).

El término “Electroencefalograma” fue introducido por primera vez por el psiquiatra alemán Hans Berger (1920), quien lo refería como el registro de las variaciones en el potencial del cerebro (Barrett, 2013).

Guyton y Hall definen a las ondas cerebrales como las ondulaciones de los potenciales eléctricos recogidas en la superficie cerebral o en la superficie de la cabeza, las cuales manifiestan que existe una actividad eléctrica cerebral constante (Hall, 2017).

Los electroencefalogramas facilitan y apoyan en el estudio de muchas áreas del conocimiento, no solo la medicina. Por ejemplo, la psicología, en la cual los EEG han facilitado desde la aplicación de pruebas psicológicas hasta la evaluación de la activación de determinadas regiones cerebrales para estudios de cognición (Romero & Díaz, 2001). También se aplican en videojuegos, educación, investigación científica (NeuroSky, 2015b), rehabilitación (RL, 2017) o ciber-seguridad (Alomari et al., 2017).

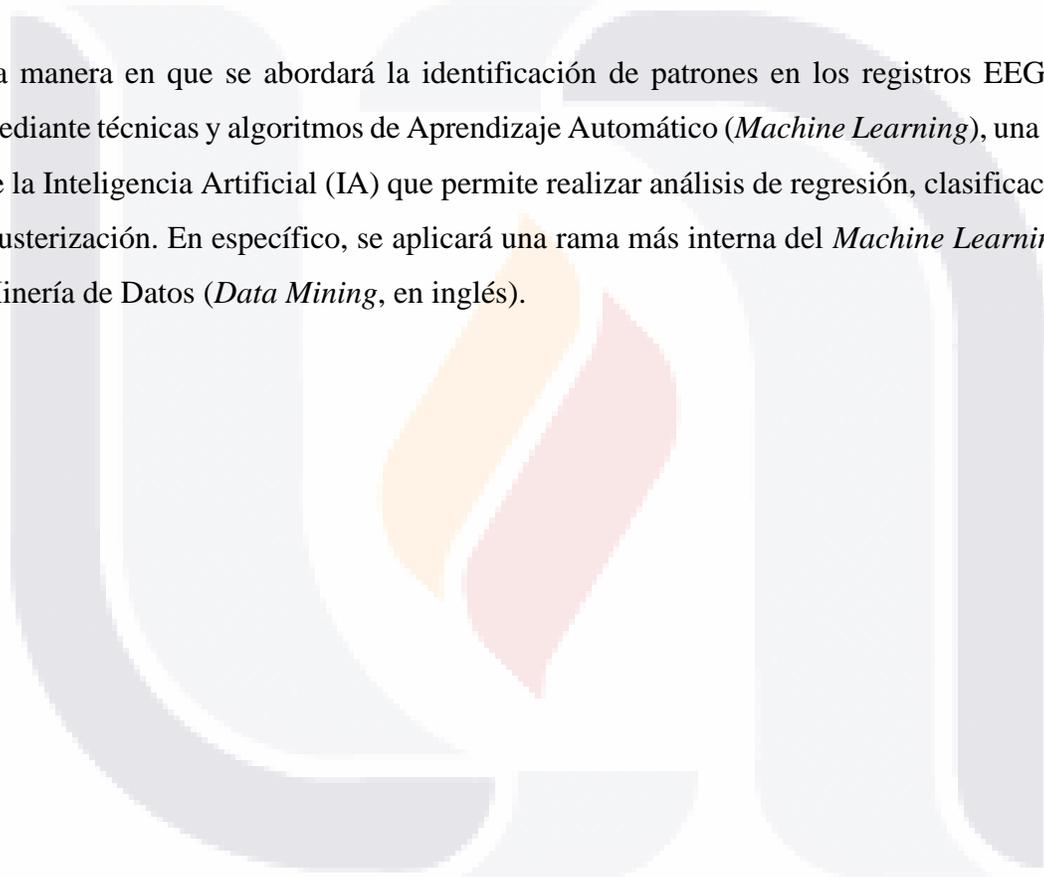
Los EEG también se han utilizado para determinar problemas de aprendizaje en niños, por ejemplo, Farnham-Diggory sugiere que, si los niños que tienen dificultad en el aprendizaje tienen lesiones cerebrales leves, es de esperar que existan anomalías en sus ondas cerebrales (Farnham-Diggory, 1983). También se pueden utilizar en campos de la medicina, por ejemplo, para determinar las características de los episodios epilépticos (Rueda Cebollero, 2012).

Como se observa mediante los ejemplos antes mencionados, el estudio de la actividad cerebral mediante EEG sirve para muchos campos de la ciencia muy variados. Para el caso

de la experimentación aquí presentada, se utilizarán estudios de electroencefalografía para identificar características del aprendizaje durante la realización de pruebas (tareas) de distintos campos de la cognición, como la memoria o el aprendizaje. Dichas tareas se aplican a dos tipos diferentes de personas, con ceguera y normovisuales.

La intención de evaluar distintas tareas cognitivas con estos dos tipos diferentes de personas recae en la comprobación del aprendizaje equitativo, garantizando la inclusión, la accesibilidad y la igualdad en la adquisición de conocimientos.

La manera en que se abordará la identificación de patrones en los registros EEG será mediante técnicas y algoritmos de Aprendizaje Automático (*Machine Learning*), una rama de la Inteligencia Artificial (IA) que permite realizar análisis de regresión, clasificación o clusterización. En específico, se aplicará una rama más interna del *Machine Learning*, la Minería de Datos (*Data Mining*, en inglés).



Capítulo I: Formulación de la Investigación.

1.1 Antecedentes.

En la Conferencia Internacional sobre Seguridad, Análisis de Patrones y Cibernética, celebrada en Shenzhen, China en 2017, un grupo de investigadores presentaron su trabajo "A symbolic representation approach of EEG signals for emotion recognition" acerca del reconocimiento de emociones basado en señales de electroencefalograma (EEG) mediante una representación simbólica. Los autores proponen dicha representación simbólica para mejorar la interpretabilidad de las señales EEG similares (Du, Xu, & Wen, 2017).

En la misma conferencia, se presentó otro trabajo relativo a la interpretación de señales EEG, basado en las redes neuronales convolucionales para la identificación de estados mentales. (Wen, Xu, & Du, 2017). En otro trabajo presentado en la Conferencia Internacional sobre tendencias en Electrónica e Informática celebrada en Tirunelveli, India en 2017, en el artículo, "Initial Analysis of Brain EEG Signal for Mental State Detection of Human Being", los autores proponen un análisis inicial de la señal EEG para posterior desarrollo del Sistema Inteligente de Reconocimiento de emociones (Figura 1) (Kimmatkar & Babu, 2017).

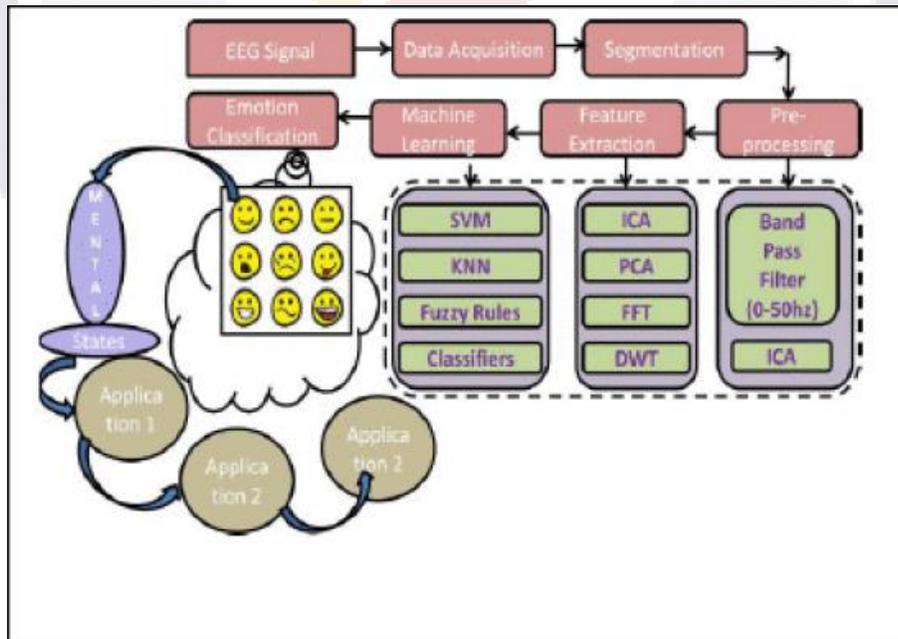


Figura 1 Sistema propuesto por los autores en el artículo "Initial Analysis of Brain EEG Signal for Mental State Detection of Human Being"(Kimmatkar & Babu, 2017).

Por otro lado, no todos los trabajos desarrollados con EEG tienen que ver con reconocimiento de emociones o de estado mental del ser humano, también hay de índole de procesamiento digital de señales, como el trabajo presentado en el 10° Congreso Internacional de procesamiento de imágenes y señales, ingeniería biomédica e informática (CISP-BMEI), donde, los autores del artículo *“EEG detection and de-noising based on convolution neural network and Hilbert-Huang transform”* buscan reducir el ruido principalmente proveniente de electrooculografía que interfiere en la señal electroencefalográfica mediante una red neuronal convolucional y la transformada de Hilbert-Huang (S. Wang, Guo, Zhang, Bai, & Wang, 2017).

Es decir, el trabajo antes mencionado se centra en el procesamiento y filtrado de la señal para eliminar ruido para obtener una señal electroencefalográfica más pura que en una posible aplicación de interpretación de la señal.

Cabe mencionar también un artículo presentado en la Life Sciences Conference (LSC) en 2017 celebrada en Australia, titulado *“EEG analysis of color effects using effective connectivity based on graph theory during a multimedia learning task”* en el cual, mediante la conexión efectiva sustentada en la Teoría de Grafos, se muestra que hay mayor interacción entre ciertas zonas del cerebro para ciertos rangos de frecuencia de las ondas cerebrales (Chai, Saad, Kamel, & Malik, 2017).

En clínica, los médicos pueden realizar diagnósticos basándose en el análisis e interpretación manual de un electroencefalograma para identificar diversos tipos de patologías, como los ya mencionados en la introducción. Este análisis conlleva mucho tiempo y la capacitación de médicos o neurofisiólogos, además de que tiene un Inter-rater reliability bajo (grado para medir el acuerdo entre calificadoras. En el artículo *“Deep Learning Enabled Automatic Abnormal EEG Identification”*, los autores destacan que el volumen de datos y la velocidad de adquisición conllevan a un proceso costoso y una interpretación lenta. Por lo cual, mediante su investigación, proponen mejorar el cuidado del paciente mediante la automatización de estos procesos. Mediante la aplicación de

TESIS TESIS TESIS TESIS TESIS

técnicas de *Machine Learning*, se pretende distinguir si un registro electroencefalográfico es normal o no. Destaca la aplicación de redes neuronales profundas que aprendan representaciones significativas de los registros, las técnicas de preprocesamiento y la aplicación de diferentes algoritmos para comparar su rendimiento. Para la realización del estudio se utilizó el *dataset* “*Temple University Hospital EEG Abnormal Corpus*”. Según sus resultados, la aplicación de redes neuronales recurrentes de compuertas profundas logra 3.47% mejores resultados que los anteriormente realizados (Roy, Kiral-Kornek, & Harrer, 2018).

De manera similar al estudio anterior, en el artículo “*EEG Pathology Detection Based on Deep Learning.*” trata de identificar ciertas patologías cerebrales, debido a que varias de ellas afectan las ondas cerebrales que se registra en el EEG, basado en aprendizaje profundo. Con el sistema que proponen los autores, las señales del EEG bruto se procesan de manera espacio - temporal. Esta forma espacio – temporal de las señales EEG es la entrada a una Red Neuronal Convolutiva (CNN).

Se utilizan dos modelos diferentes de CNN con distinta profundidad (uno de ellos poco profundo). Aunado a lo anterior, también se investiga una estrategia de fusión basado en un perceptrón multicapa (MLP). De igual manera que el artículo anterior, también se utiliza el *dataset* “*Temple University Hospital EEG Abnormal Corpus*”. El sistema propuesto del modelo profundo CNN y la fusión alcanza una precisión del 87.96%, según los autores, mejor que algunos reportados en el mismo corpus (Alhussein, Muhammad, & Hossain, 2019).

En la revista IEEE Access de agosto 2017, en un artículo llamado “*Machine Learning Framework for the Detection of Mental Stress at Multiple Levels*”, se propone un framework (marco de trabajo) basado en *Machine Learning* para clasificar los diferentes niveles de estrés mediante el análisis de las señales EEG (Véase Figura 2) (Subhani, Mumtaz, Saad, Kamel, & Malik, 2017):

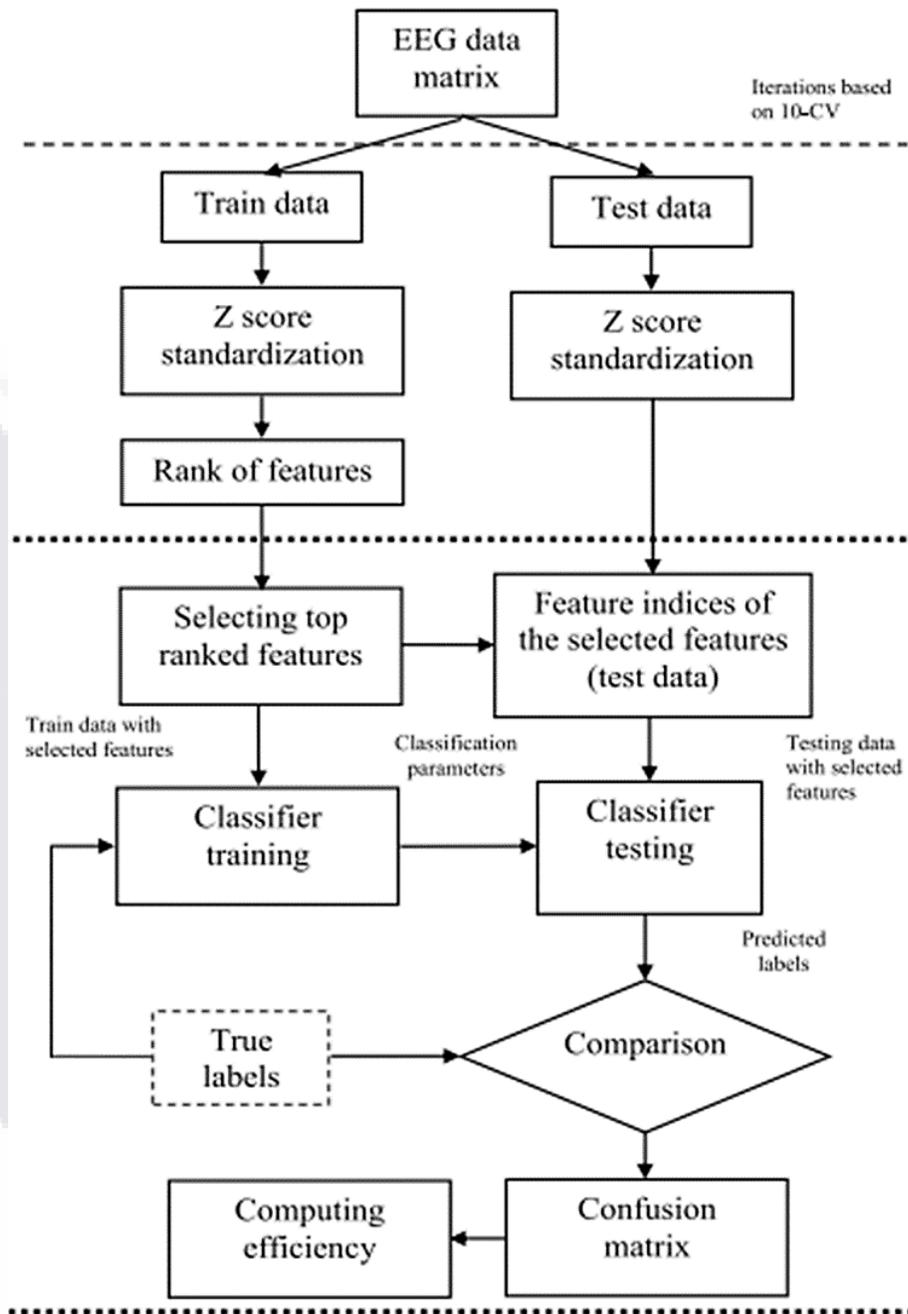


Figura 2 Framework propuesto para la clasificación de estados mentales (Subhani et al., 2017).

También en IEEE Access agosto de 2017, se expone el trabajo “*Optimal Feature Selection and Deep Learning Ensembles Method for Emotion Recognition from Human Brain EEG Sensors*” en el cual, mediante el análisis de EEG y aplicando técnicas de *Machine*

Learning, se logran identificar diferentes estados emocionales. Para la experimentación, se registraron los datos de EEG de 21 personas sanas de 12 a 14 años usando un electroencefalógrafo de 14 canales al tiempo que los sujetos miraban imágenes con cuatro tipos de estímulos distintos (feliz, tranquilo, triste y asustado) (Mehmood, Du, & Lee, 2017).

Durante la International Conference on Intelligent Systems (IS) del 2018, se presentó el trabajo titulado “*A Study on Mental State Classification using EEG-based Brain-Machine Interface*” en el cual, se pretenden encontrar características basadas en EEG y métodos de clasificación apropiados que logren categorizar los patrones de onda cerebrales en función de su nivel de actividad o frecuencia para el reconocimiento del estado mental con la intención de ser utilizados en proyectos HCI (Interacción Humano-Computadora), cabe aclarar, que para el registro EEG (Bird, Manso, Ribiero, Ekart, & Faria, 2018), se utilizó la diadema Muse de cuatro sensores (TP9, AF7, AF8, TP10) del sistema de colocación 10-20 (Figura 3):

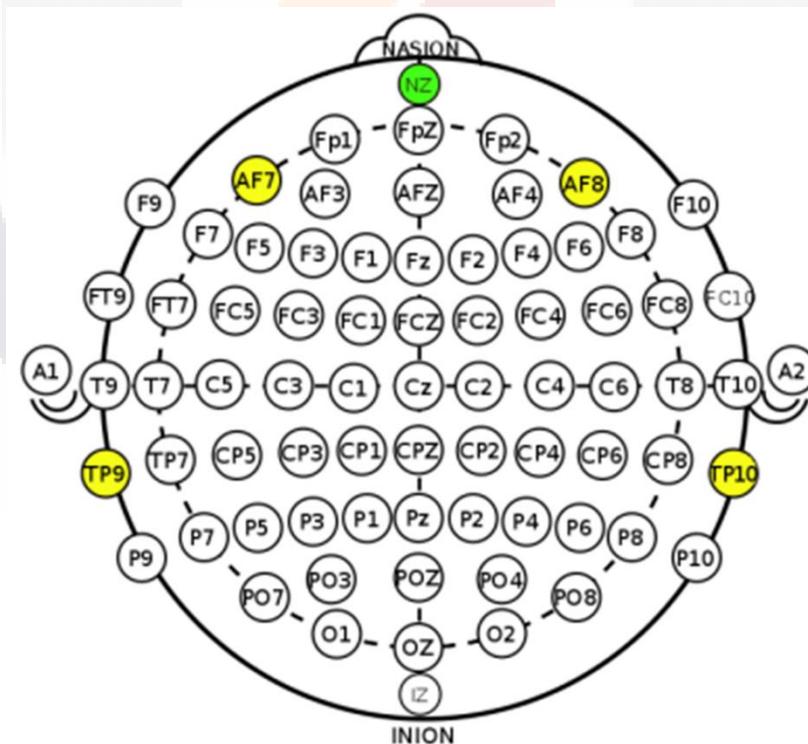


Figura 3 Canales utilizados para el registro EEG en el artículo anteriormente mencionado (Jasper, 1958).

Desde los grandes avances que han tenido las neurociencias y la computación, se conjuntó un concepto interesante que mezcla la adquisición de las señales eléctricas provenientes de la corteza cerebral (ondas EEG) con su procesamiento en una computadora, las interfaces Cerebro-Computadora. Actualmente, existen bastantes trabajos e investigaciones relativos a las interfaces cerebro-computadora, como muestra de los antecedentes en esta área que implica tanto las neurociencias como la computación, a continuación, se muestran algunos ejemplos:

- **Videojuegos:** Como NeuroWikium, programa desarrollado para PC, que consta de siete diferentes juegos para entrenar el cerebro, centrados en los niveles de atención y meditación con la diadema *MindWave* de NeuroSky como Brain-Computer Interface (BCI) (NeuroSky, 2015c).
- **Rehabilitación:** Como el sistema de rehabilitación del síndrome de miembro fantasma realizada por alumnos de la Escuela de Ingeniería de Antioquía-Grupo GISMOC de Colombia, el cual incorpora la diadema Emotiv EPOC como BCI y un sistema de realidad aumentada para apoyo de pacientes amputados (Arango, Mazo, & Palacio, 2013). O el proyecto X-Chair, que fue el proyecto ganador del reto de Salud Pública del concurso nacional Vive conciencia 2016. Consiste en una silla de ruedas controlada mediante BCI por medio de una diadema que direcciona la silla según los niveles de meditación. Los desarrolladores de la silla la nombraron de este modo debido a que se basaron en la popular silla de ruedas del Profesor Charles Xavier (personaje y líder ficticio de X-men) (RL, 2017).
- **Educación:** Como la App Effective Learner, desarrollada para iOS o Android por la compañía NeuroSky, que trata de encontrar el mejor momento para estudiar y aprender algo nuevo según el nivel de atención que se brinda al estudio (NeuroSky, 2015a). Este tipo de proyectos están más relacionados con la medición de aprendizaje.

- **Investigación:** Como EEGLab, un toolbox de Matlab que permite procesar y analizar señales electroencefalográficas (EEG) desarrollado por Swartz Center for Computational Neuroscience de la UC San Diego (SCCN, 2018).

2.1 Problemática de la Investigación.

Actualmente en el mundo, se trata mediante diferentes esfuerzos institucionales, evitar cualquier tipo de segregación, discriminación o alejamiento de determinados sectores de la población (ya sea por razones de discapacidad, orientación sexual, género, religión, raza, nacionalidad, condición socioeconómica, etc.). En lo que confiere al campo de la educación y a las personas con discapacidad, se han desarrollado distintos modelos que buscan la integración plena de niños y jóvenes (en todos los niveles educativos) a las aulas en igualdad de oportunidad con todos sus compañeros.

Si bien, este trabajo no profundiza en los modelos de educación inclusiva, si parte de este tema para resaltar que, aunque existen modelos integradores e incluyentes, no se cuenta con metodologías o herramientas orientadas al aprendizaje homogéneo mediante análisis de señales cerebrales (EEG) o actividad cerebral (como estudios de Resonancia Magnética, no abordado en esta investigación) en atención, aprendizaje significativo, experiencia de aprendizaje, etc.

Lo anterior no quiere decir que los modelos estén incompletos únicamente por no utilizar estos enfoques, pero en esta investigación se proponen mediciones iniciales con análisis orientado a la búsqueda de patrones en señales hacia el nivel de atención durante actividades de aprendizaje.

La experimentación y mediciones realizadas en esta investigación, así como el proceso metodológico empleado no pretenden ser concluyentes, sino una primera aproximación que se suma a los esfuerzos de la búsqueda de la garantía de un aprendizaje en igualdad de condiciones sin importar la discapacidad que pudieran presentar los alumnos.

Para este caso en particular, la investigación se centra en dos poblaciones, personas con ceguera y normovisuales (sin problemas graves de vista) las cuales participan en un mismo entorno con videos de divulgación científica para medir sus niveles de atención mediante un *headset* y la implementación de Minería de Datos.

1.3 Preguntas de Investigación.

1.3.1 Pregunta general.

¿Qué características relacionadas a la atención pueden encontrarse en los registros electroencefalográficos (EEG) al realizar una actividad enfocada al aprendizaje entre personas ciegas y normovisuales?

1.3.2 Preguntas específicas.

- ¿Cuáles son las ondas cerebrales más asociadas a la atención?
- ¿Qué algoritmos de *Machine Learning* pueden aplicarse a estos registros para una efectiva diferenciación?
- ¿Hay diferentes ondas cerebrales asociadas a la atención según sea el participante ciego o normovisual?
- ¿Con qué actividades se pueden comparar los registros entre personas con ceguera y normovisuales en un enfoque de aprendizaje?

1.4 Objetivos de Investigación.

1.4.1 Objetivo general.

Identificar las principales características asociadas a la atención en usuarios con ceguera y normovisuales presentes en los registros electroencefalográficos mediante Minería de Datos durante la realización de actividades de aprendizaje y memoria.

1.4.2 Objetivos específicos.

- Revisar teoría y modelos de análisis de señales EGG relacionadas clasificación mediante algoritmos de *Machine Learning* (Minería de Datos)
- Proponer actividades de aprendizaje que puedan ser fácilmente adaptables entre los diferentes tipos de usuarios y que a la postre, mediante ellas, se realizarán los registros EEG.
- Construir las bases de datos de los registros para participantes ciegos y normovisuales de estudio y compararlas para identificar características de cada una.
- Implementar un algoritmo de *Machine Learning* (Minería de Datos) para el análisis e interpretación de los registros EEG.

1.5 Justificación.

La tesis se contempla como la etapa de pruebas y validación de un proyecto de investigación más grande titulado “*Modelo de producción y aplicación de ambientes de aprendizaje adaptativo para la atención de niños y jóvenes con discapacidad para favorecer su inclusión en el salón de clases*” que se desarrolla en la Escuela Normal Superior del Estado de Aguascalientes (ENSFA) para capacitar a los profesores mediante diversos métodos y el uso de las TIC’s en la enseñanza conjunta de alumnos con y sin discapacidad (para este caso, centrado en alumnos ciegos y normovisuales). De hecho, recientemente, se han incluido en la currícula de los alumnos de la ENSFA, materias sobre lenguaje de señas (para alumnos con problemas auditivos) y sobre lectoescritura Braille (para alumnos con problemas visuales) (RadioBI, 2019).

La finalidad principal es determinar las principales diferencias en los patrones de atención entre las personas ciegas y normovisuales, con miras a posteriores trabajos de investigación aplicados al área de la educación y docencia.

Aunado a lo anterior, la investigación hace uso de las herramientas y tecnologías emergentes relacionadas al *Machine Learning*, como parte de un método de análisis emergentes aplicadas a cualquier infinidad de ramas de la ciencia desde este nuevo paradigma.

Como parte importante, cabe señalar que, al tratarse de pruebas y validación, la tesis en realidad comprende la etapa final del proyecto de investigación y de Ing. de *software* más grande mencionado anteriormente.

Capítulo II: Marco Teórico.

En esta sección, se presentan algunos conceptos claves que vale la pena ser destacados para dar fundamento teórico al trabajo de investigación.

Como primer punto, se presenta “Electroencefalografía”, tema de relevancia para entender cómo es el registro de las señales cerebrales que a la postre serán utilizadas para medir el aprendizaje (enfocado a la atención).

También se revisarán conceptos como Aprendizaje y Memoria, Ceguera, *Machine Learning*, Minería de Datos y Ciencia de Datos.

2.1 Electroencefalografía.

Existen potenciales sinápticos producidos en los cuerpos celulares y las dendritas de la corteza cerebral que crean corrientes eléctricas que pueden medirse mediante electrodos colocados en el cuero cabelludo. El registro de estas corrientes eléctricas se llama electroencefalograma (EEG) (Fox, 2014).

La base eléctrica de fondo del encéfalo fue estudiada inicialmente en animales en el siglo XIX, pero fue el psiquiatra alemán Hans Berger, quien introdujo el término de electroencefalograma (EEG) refiriéndose al registro de variaciones en el potencial del cerebro. Puede registrarse con electrodos en la piel cabelluda con el cráneo intacto o con electrodos sobre o dentro del cerebro (Ej. corticograma). El registro del EEG en la piel cabelluda es una medida de la suma de potenciales postsinápticos y no de potenciales de acción (Barrett, 2013).

El EEG es registrado de electrodos metálicos localizados sobre el cuero cabelludo. Los electrodos son cubiertos con una pasta conductora, luego se localizan sobre el cuero cabelludo donde se adhieren. La localización de los electrodos de registro generalmente se basa en el sistema internacional 10-20, donde la ubicación de los electrodos está determinada por las medidas de 4 posiciones estándar en la cabeza: nasion, inion, puntos preauriculares derecho e izquierdo (Figura 4) (Aminoff, 2012).

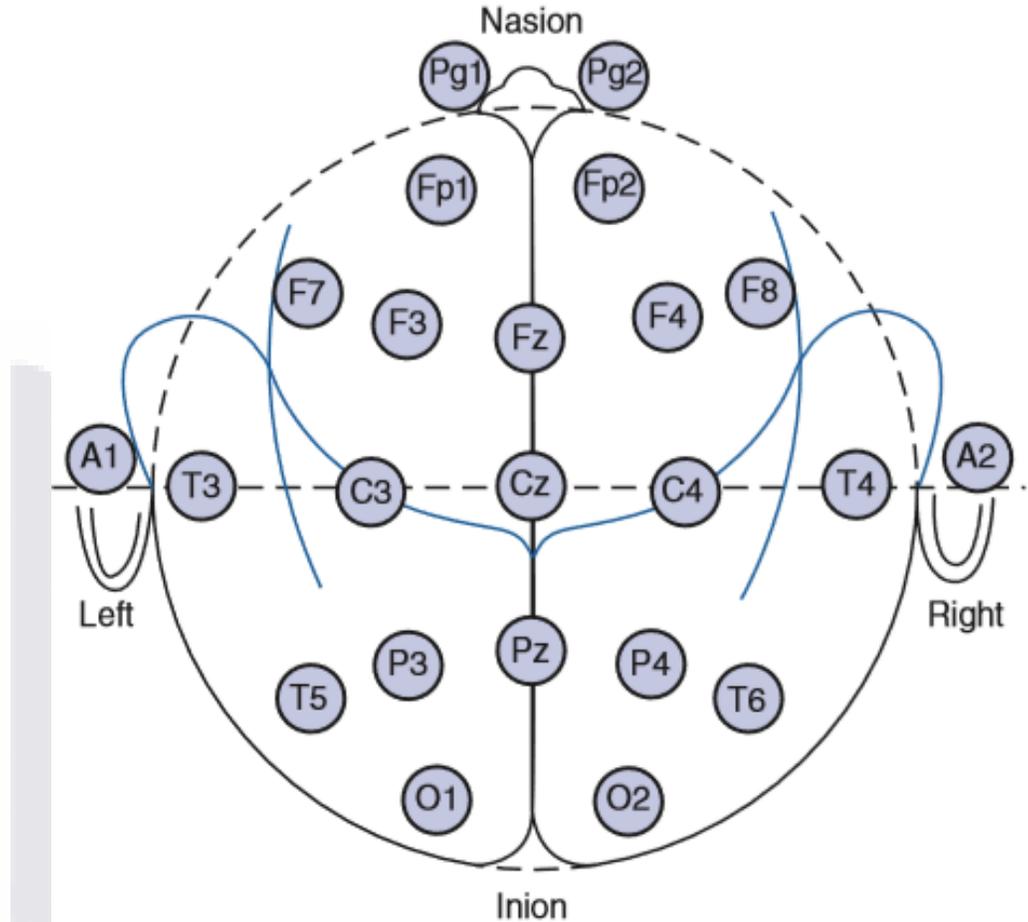


Figura 4 El sistema internacional 10-20 de localización de electrodos. A, oreja; C, central; F, frontal; Fp, frontal polar; P, parietal; Pg, nasofaríngeo; T, temporal; O, occipital. El lado derecho se registra con números pares y el lado izquierdo con números nones y en la línea media con Z (Aminoff, 2012).

Con este sistema, la distancia entre los electrodos es de 5-7 cm en adultos. Las diferencias de potenciales entre los electrodos son amplificadas y registrados continuamente mediante sistemas digitales comúnmente, los cuales permiten la reconstrucción del EEG con cualquier derivación deseada o formato y también permite el manejo de la información para análisis posteriores (Aminoff, 2012).

Como se ha indicado, la diferencia de potencial entre un par de electrodos o entre un electrodo y su punto de referencia, es amplificado antes de ser reproducido en papel o en

un monitor. Los cables de entrada de los amplificadores individuales son diseñados como negro (terminal de entrada 1 o G1) y blanco (terminal de entrada 2 o G2). Están arreglados de manera que cuando el electrodo esté conectado con la terminal negra es relativamente más negativa que cuando están conectados con el blanco, y es lo que produce la desviación del trazo. Con las derivaciones de referencia, cada uno de los electrodos activos sobre el cuero cabelludo está conectado a la terminal negra de un amplificador, y todas las terminales blancas están conectados con un punto de referencia común (En los electroencefalógrafos comunes) (Aminoff, 2012).

Procedimientos de activación (Aminoff, 2012):

- Hiperventilación: por 3 o 4 minutos es un método usualmente bien aceptado para provocar o acentuar anomalías en el EEG, pero no debe realizarse en pacientes que recientemente han sufrido un EVC, ataque isquémico transitorio o hemorragia subaracnoidea, o en casos de enfermedad de Moya-moya, enfermedad cardíaca o respiratoria severa, estados de hiperviscosidad o en casos de enfermedad de células falciformes.
- Registro durante el sueño o después de un periodo de 24 horas de privación del sueño también puede provocar anomalías en el EEG.
- Otra forma de evocar anomalías también es realizada con estímulos estroboscópicos para causar un ritmo de foto estimulación mientras se registra el EEG utilizando un registro bipolar que cubra particularmente el área occipital y parietal.
- Varios estímulos auditivos también pueden precipitar anomalías en el EEG en pacientes con epilepsia, aunque no es una prueba que suele realizarse de manera rutinaria, excepto en casos de evaluación de pacientes en estado de coma.

2.1.1 Artefactos.

Existe una gran variedad de artefactos a la hora de realizar una evaluación por EEG, estos artefactos pueden surgir de los electrodos, del equipo de registro o del ambiente a la hora de hacer el registro. Por ejemplo, los llamados electrodos “pop”, resultantes de un súbito cambio en la impedancia (observado como una deflexión abrupta del trazo derivado de un electrodo particular, superpuesto en el trazo del EEG, (Figura 5), ondas de formas distorsionadas resultado de una sensibilidad inapropiada de la pantalla, ruido excesivo de los amplificadores y artefactos generados por factores medioambientales por dispositivos externos, campos electrostáticos (como de personas moviéndose alrededor del paciente), infusión intravenosa (generan trazos con forma que coincide con gotas de la infusión, posiblemente por las cargas electrostáticas), artefactos bioeléctricos que generen diferencias de potenciales no cerebrales como artefactos oculares, cardíacos, musculares y de movimiento, deglución o glosocinéticos (Aminoff, 2012).

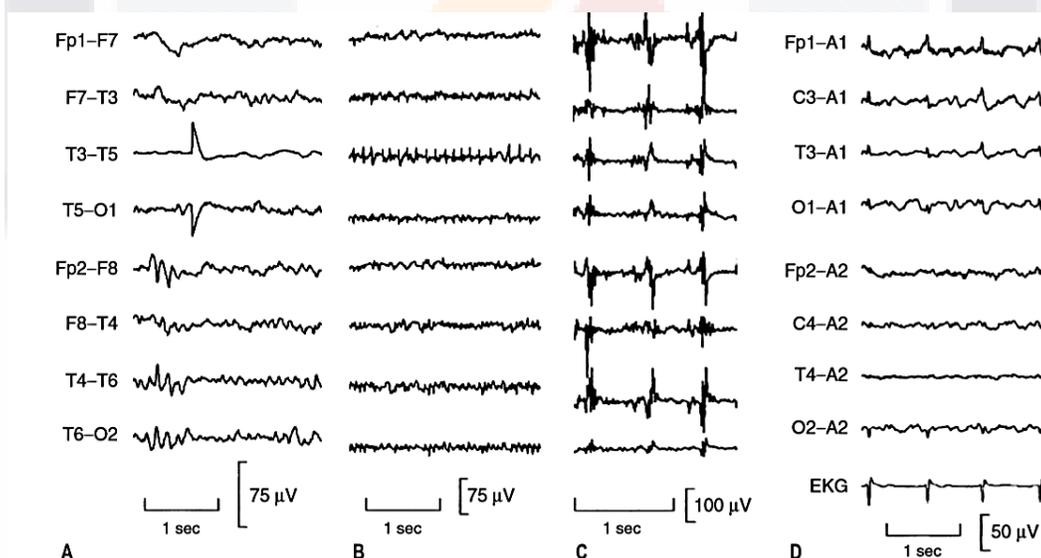


Figura 5 Artefacto surgiendo en electrodo T5. B, artefacto electromiográfico en la región temporal izquierda. C, artefacto de masticación. D, artefacto electrocardiográfico (Aminoff, 2012).

2.1.2 Interpretación del EEG.

La evaluación del EEG para propósitos clínicos o de investigación incluye definición de la frecuencia, amplitud y distribución de la actividad eléctrica presente y la respuesta a

estímulos externos como la apertura ocular. El grado de sincronía y simetría de ambos hemisferios o lados de la cabeza debe evaluarse. La presencia de cualquier actividad focal es determinada por las características de su naturaleza. Los hallazgos deben ser interpretados en relación con la edad del paciente y al nivel de excitación. Para propósitos descriptivos, la actividad EEG es usualmente caracterizada con base en su frecuencia (Aminoff, 2012).

2.1.3 Registro de actividad en el EEG.

Los mecanismos responsables para la presencia de actividad rítmica extensa en el cerebro son desconocidos. Se han teorizado la relación con mecanismos de generación de actividad rítmica, así como también algunos métodos de sincronización de la actividad de diferentes regiones cerebrales. Experimentos en modelos animales han producido evidencia considerable que sugiere que la actividad rítmica normalmente registrada desde el cuero cabelludo tiene un origen cortical, derivando desde el grado de potenciales postsinápticos de neuronas corticales, estas son las neuronas piramidales, células orientadas verticalmente con respecto a la corteza, que tienen una dendrita apical que se extiende hasta la superficie, y que están localizadas en las capas corticales III, V y VI (Aminoff, 2012).

Los factores que determinan si un potencial cortical es registrado sobre el cuero cabelludo incluyen su voltaje, la extensión de la cual las células generadoras están descargando sincrónicamente, el área de corteza involucrada y el sitio de participación con respecto a las circunvoluciones. La sumación espacial de la actividad cortical es importante en la producción de los campos de voltaje que son registrados en el EEG en el cuero cabelludo debido a las propiedades de atenuación del cráneo y otros tejidos interpuestos. Por último, se ha relacionado la integridad de áreas subcorticales con la sincronización de las señales registradas en el EEG, por ejemplo, se ha aceptado de manera general que el tálamo funciona como el marcapasos de ciertos ritmos corticales que son registrados durante la electroencefalografía, pero los circuitos intra corticales también influyen significativamente. El EEG es una representación bidimensional de una actividad tridimensional que puede errar en proveer suficiente información para permitir la

localización única de los generadores neuronales de una fuente de corriente intracraneal, lo que es conocido como “el problema inverso” (Aminoff, 2012).

Para los EEG clínicos comunes, se tiene (García, 2011):

2.1.4 Tipos de Montajes.

- Electrodo: elemento situado en el punto de registro, (de cucharilla o de aguja), y el hilo metálico que lo une al aparato amplificador.
- Derivación: los dos electrodos que se conectan a cada canal de amplificación.
- Montaje: conjunto de derivaciones. Se utilizan 2 tipos de montajes: bipolares y monopolares o referenciales.
- Montaje bipolar: en el canal de amplificación, tanto el electrodo situado en posición 1 como el situado en posición 2, registran actividad cerebral y la diferencia entre los dos puntos. Es lo que va al amplificador para su registro. Pueden ser de 2 tipos: antero - posteriores (Sagitales) o transversos (Coronales).
- Montaje monopolar: los electrodos exploradores ocupan la posición 1 del amplificador, mientras que la posición 2 está ocupada por un electrodo relativamente inactivo o que sea común para todos los canales.

Existen unas reglas convencionales dentro de la electroencefalografía para la elaboración de un registro de EEG que son:

- Los montajes deben de ser tan simples como sea posible. Se programan siguiendo 2 reglas internacionales: siempre de áreas anteriores hacia posteriores, y primero el lado izquierdo y luego el derecho.
- Se utilizan 2 montajes bipolares (uno antero - posterior y otro transversal), y un montaje monopolar o referencial, donde cada electrodo es referido a un punto único para todos y que es considerado neutro.
- Debe sujetarse al sistema 10-20 para su correcta interpretación.

2.1.5 Características de la actividad cerebral.

La actividad cortical recogida en el EEG se compone de un número variado de ondas que aparecen aisladas o en grupos (ritmo). Estas ondas, se diferencian unas y otras por los siguientes parámetros:

Frecuencia: Según su rango de frecuencia, las ondas electroencefalográficas se dividen en (Aminoff, 2012):

- **Ritmo Delta:** Actividad menor de 4 Hz está designada como actividad delta. La actividad de este tipo es la predominante en niños y es un hallazgo normal durante estadios profundos del sueño en sujetos mayores. Cuando se presenta en EEG de adultos despiertos, la actividad delta es un hallazgo anormal. La actividad lenta tiene una frecuencia de aproximadamente 3 Hz, está presente durante el despertar, en respuesta a la apertura ocular y puede reforzarse con la hiperventilación.
- **Ritmo Theta:** La actividad con una frecuencia entre 4-7 Hz conocida como actividad theta. La actividad theta y más lenta es usualmente más destacada en niños, pero se vuelve menos prominente cuando ellos maduran. Alguna actividad Theta es a menudo encontrada en adultos jóvenes, particularmente sobre regiones temporales y durante hiperventilación, pero en sujetos mayores la actividad theta tiene una amplitud de alrededor de 30 μ V es menos observada, excepto durante la somnolencia. No está presente durante el sueño, su origen es incierto.
- **Ritmo Alfa:** El ritmo alfa tiene una frecuencia de entre 8 y 13 Hz, pero en la mayoría de los adultos se encuentra entre 9-11 Hz. Este ritmo se encuentra más comúnmente en las regiones posteriores de la cabeza durante el desvelo, pero también está presente en regiones central o temporal. Se observan mejor cuando el paciente está descansando con los ojos cerrados. El ritmo alfa es atenuado o abolido con la atención visual (Figura 6) y se afecta de manera transitoria por otros estímulos y otras actividades de alerta mental (aritmética) o por ansiedad. El

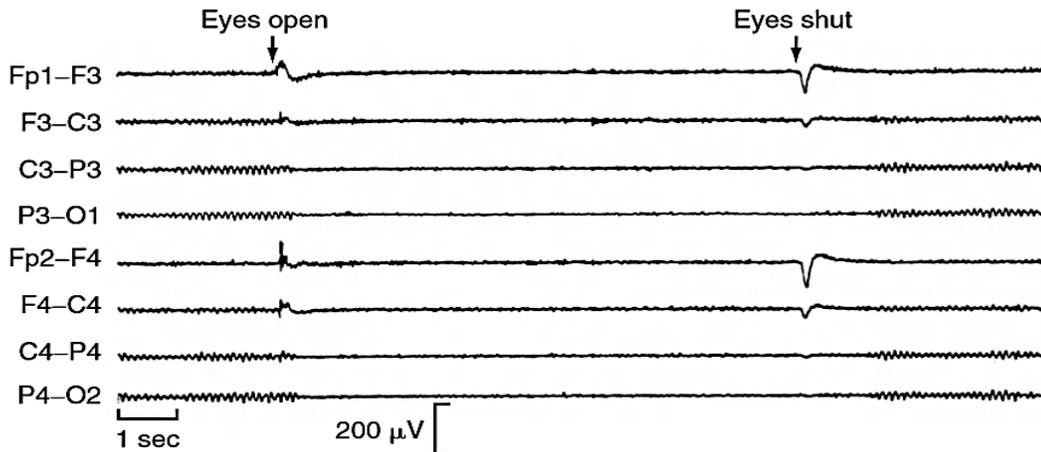


Figura 6 Ritmo alfa normal 9-10 Hz registrado en el EEG de un hombre de 64 años. Se puede ver la distribución posterior y respuesta del ritmo al abrir los ojos (Aminoff, 2012).

- Ritmo Beta:** cualquier actividad rítmica que tiene una frecuencia mayor a 13 Hz se refiere a actividad beta. Actividad de este tipo se presenta en el EEG de la región anterior de adultos sanos. La actividad beta, la respuesta a la apertura ocular, es en ocasiones encontrada sobre regiones posteriores de los hemisferios cerebrales y entonces es considerada ocasionalmente como una variante rápida del ritmo alfa. Habitualmente tiene una amplitud de menos de 30 μV . La cantidad de dicha actividad varía considerablemente entre sujetos anormales. La actividad tiene una frecuencia entre 18-25 Hz es habitualmente más sobresaliente durante la somnolencia, sueño ligero y sueño REM (movimientos oculares rápidos, por sus siglas en inglés). También puede aumentarse durante tareas cognitivas.
- Ondas Lambda:** Son ondas de forma electropositivas que pueden ocurrir en la región occipital en sujetos normales que están observando o escaneando algo (ej. leyendo) en un campo bien iluminado, particularmente si su atención e interés están estimulados. Actividad morfológicamente similar es en ocasiones observada durante el sueño no-REM.

- **Ondas trifásicas:** Son típicamente consistentes con un potencial precedido por ondas negativas más pequeñas. Se encuentran más característicamente en encefalopatías metabólicas principalmente encefalopatía hepática y, ocasionalmente reactivas a estímulos externos dolorosos.
- **Descargas de espigas:** En el uso de estudio de pacientes con epilepsia, las ondas en forma de espigas en el periodo interictal es sugestivo de actividad epiléptica. La actividad epileptiforme se define como actividad paroxística anormal consistente, al menos en parte, de espigas, haladas en la mayoría de los pacientes con epilepsia (Figura 7).
- **Ritmo Gamma:** Adicionalmente, algunos autores reconocen las ondas Gamma, mayores a 30Hz. Las ondas beta y gamma juntas han sido asociadas con la atención, la percepción y la cognición (Torres, Sánchez, & Baus, 2014).

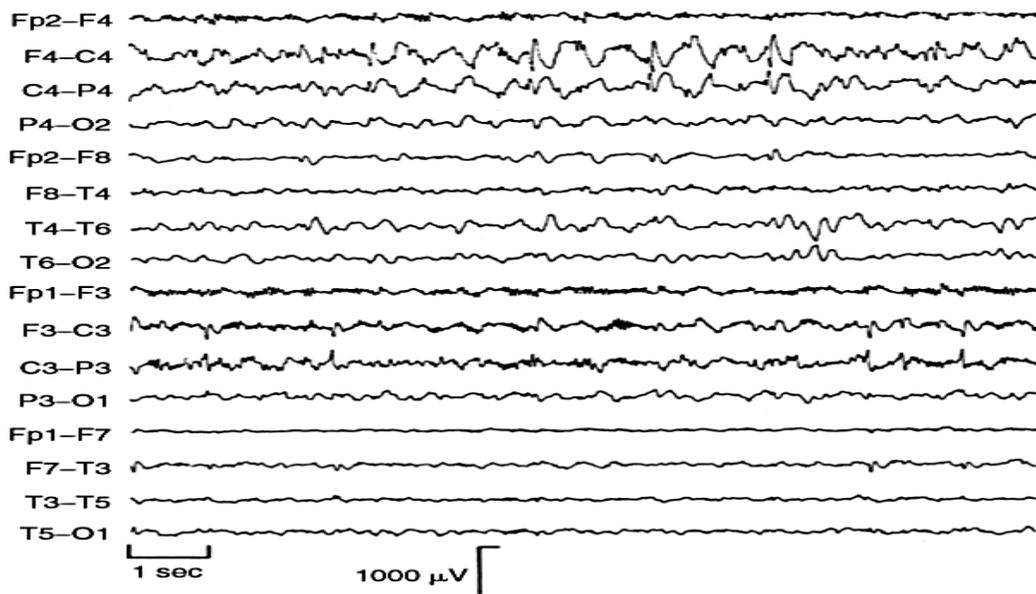


Figura 7 Descarga de espigas interictal surgiendo en la región central independiente de cualquier hemisferio en un paciente con convulsiones desde la infancia (Aminoff, 2012).

Distribución topográfica: Indica el lugar cerebral en el que aparece un fenómeno eléctrico. También hace referencia a la ubicación fisiológica de las distintas frecuencias dependiendo del área cerebral correspondiente. Así, en áreas anteriores, se encuentra el ritmo Beta y a medida que descendemos a áreas posteriores, nos va apareciendo el ritmo Alfa. Se utiliza el nombre de los lóbulos cerebrales correspondientes para expresar dicha distribución (García, 2011).

Forma, Amplitud y Duración: La forma de una onda aislada puede ser: regular, irregular, aguda, compleja, bifásica, trifásica, etc. La amplitud se mide en microvoltios siendo lo habitual que fluctúe entre 20-40 μV . La duración de una onda se expresa en milisegundos (ms) (García, 2011).

Reactividad: Es la capacidad de modificación de un ritmo, ante estímulos como apertura y cierre de ojos, estimulación eléctrica, proceso mental, alertamiento, etc (García, 2011).

Como siguiente punto, se expondrá la teoría relativa con el aprendizaje y la memoria, puesto que estos conceptos son la base de la experimentación de este proyecto.

2.2 Aprendizaje y memoria.

La gran aplicación de la “red de ciencia” en sistemas biológicos, sociales y tecnológicos ha permitido a las neurociencias explorar la compleja función cerebral desde una nueva perspectiva. Observando al cerebro como una red, el proceso de transferencia de información está representado por un set de nodos interconectados y bordes (Miraglia, Vecchio, & Rossini, 2018).

El estado de las redes cerebrales funcionales puede influenciar en como el cerebro maneja la información y como cambia con la experiencia en condiciones internas o externas. Estudios de IRM han demostrado que la reconfiguración dinámica de la estructura modular funcional en respuesta a la demanda de tareas está asociado con el rendimiento individual en aprendizaje de habilidades motoras, memoria de trabajo y procesos de atención. Una meta importante es encontrar la relación eventual entre la organización de

redes funcionales cerebrales y las consecuencias de conducta de entrenamiento en procesos de aprendizaje, con el objetivo de predecir el desempeño a través de medidas comparativas previas (Miraglia et al., 2018).

Uno de los problemas más difíciles al abordar la conciencia, el pensamiento, la memoria y el aprendizaje radica en, los todavía ampliamente desconocidos mecanismos nerviosos que sigue un pensamiento y lo poco que se conoce sobre el mecanismo de la memoria. Se sabe que la destrucción de grandes porciones de la corteza cerebral no impide que una persona tenga pensamientos, pero si reduce su profundidad y el grado de conciencia que ejerce sobre su medio. Es claro que cada pensamiento entraña señales simultáneas en muchas porciones de la corteza cerebral, tálamo, sistema límbico y formación reticular del tronco encefálico. Algunos pensamientos básicos dependen probablemente casi por completo de los centros inferiores, la idea del dolor sería un buen ejemplo, contrario a eso, un tipo de patrón de pensamiento que requiere gran participación de la corteza cerebral es el de la visión, debido a que la ausencia de corteza visual genera una absoluta incapacidad para percibir las formas visuales o los colores (Hall, 2017).

Se cree que las regiones estimuladas del sistema límbico, tálamo y formación reticular determinan la naturaleza general del pensamiento, otorgando cualidades como placer, dolor, sensibilidad, localización corporal y otras características. Sin embargo, zonas específicas estimuladas de la corteza cerebral condicionan rasgos diferenciados del pensamiento como localización específica de las sensaciones en la superficie del cuerpo y objetos en campo visual, sensación de textura, reconocimiento visual de patrones, otras características que forman parte del conocimiento global (Hall, 2017).

Los recuerdos se almacenan en el cerebro al variar la sensibilidad básica de la transmisión sináptica entre las neuronas como consecuencia de la actividad nerviosa previa. Las vías nuevas o vías facilitadas reciben el nombre de *huellas de memoria*, una vez que quedan establecidas, es posible activarlas de forma selectiva por los pensamientos de la mente para reproducir los recuerdos (Hall, 2017).

La memoria suele clasificarse en virtud del tipo de información almacenada. Una de estas clasificaciones la divide en memoria declarativa y memoria procedimental (Hall, 2017):

- Memoria declarativa: refiere al recuerdo de diversos detalles que forman un pensamiento integrado, como la memoria de una experiencia importante que abarca el medio en que aconteció, relaciones temporales, causas de producción, significado y deducciones particulares.
- Memoria procedimental: se asocia con las actividades motoras del cuerpo de una persona, como todas las habilidades adquiridas.

Con base en los cambios químicos presinápticos y postsinápticos donde se puede originar un recuerdo con duración de unos pocos minutos hasta semanas, en un modelo de caracol de género *Aplysia*. (Figura 8) se muestran dos terminales sinápticos, un terminal sensitivo, terminación presináptica o terminal facilitador, cuando el terminal sensitivo se estimula repetidas veces sin la activación del terminal facilitador, la transmisión de las señales es grande al principio, pero su intensidad se reduce cada vez más a medida que se reitera el proceso hasta que prácticamente cesa su paso, este fenómeno se conoce como habituación. El mecanismo de habituación obedece al cierre creciente de los canales de calcio que atraviesan la membrana del terminal, aunque no está muy claro este proceso(Hall, 2017).

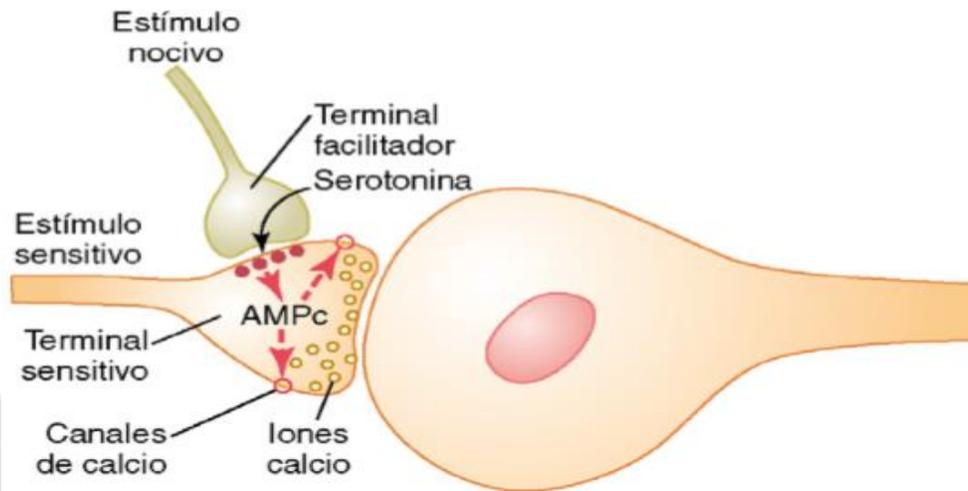


Figura 8 Sistema de memoria descubierto en el caracol Aplysia (Hall, 2017).

Para que se lleve a cabo el proceso de consolidación de la memoria, la memoria a corto plazo se activa repetidas veces, pondrá en marcha unos cambios anatómicos, físicos y químicos en las sinapsis que son responsables del tipo de memoria a largo plazo. La consolidación y el tiempo necesario para que suceda probablemente pueden explicarse recurriendo al fenómeno de la repetición de la memoria a corto plazo. La repetición potencia la transferencia desde la memoria a corto plazo hasta la memoria a largo plazo, los recuerdos nuevos se codifican durante la consolidación basados en asociaciones con otros recuerdos del mismo tipo (Hall, 2017).

Uno de los modelos más básicos de aprendizaje es el modelo Pavloviano, basado en el trabajo del Dr. Ivan Petrovic Pavlov (1849-1936), donde un estímulo neutral se asoció con una respuesta psicológica, es decir, determinado estímulo evoca una serie de respuestas y emociones (Sadock & Ruiz, 2015).

El entendimiento del desarrollo de la memoria ha derivado de estudios sobre la amnesia, y se ha extendido gracias a estudios de imagen como ya se mencionó, teniendo un papel elemental la resonancia magnética (IRM) y la tomografía por emisión de positrones (TEP). Por ejemplo, la activación de regiones prefrontales posteriores demostrada mediante de TEP y reforzada con IRM han relacionado estas regiones con un

procesamiento estratégico durante la recuperación como la memoria de trabajo. Además, se han identificado contribuciones al procesamiento de memoria por la corteza parietal. Múltiples regiones parietales (incluyendo lóbulos inferior y superior, uncus, cingular posterior, corteza retrosplenial) son activadas en conjunto con recuerdo de experiencias recientes. Mecanismos neurales apoyan la recuperación de la memoria implícita y declarativa que se ha distinguido mediante el registro de la actividad eléctrica, demostrando la diferencia entre la memoria declarativa y la implícita mediante las señales de actividad que se origina en diferentes regiones cerebrales (Sadock & Ruiz, 2015).

La actividad hipocampal relacionada con la recuperación de la memoria se ha observado en pruebas de memoria con diferentes tipos de estímulos. También, el hipocampo es activado durante el almacenamiento inicial de la información, mientras que la corteza prefrontal inferior se dedica, como resultado de intentos para codificar una palabra que está más íntimamente relacionada, dependiendo si esta conduce a una memoria estable, que puede ser recuperada. (Figura 9). Estos hallazgos confirman la idea de que las regiones medial temporal y frontal son importantes como almacenamiento de memoria y contribuyen de maneras diferentes (Sadock & Ruiz, 2015).

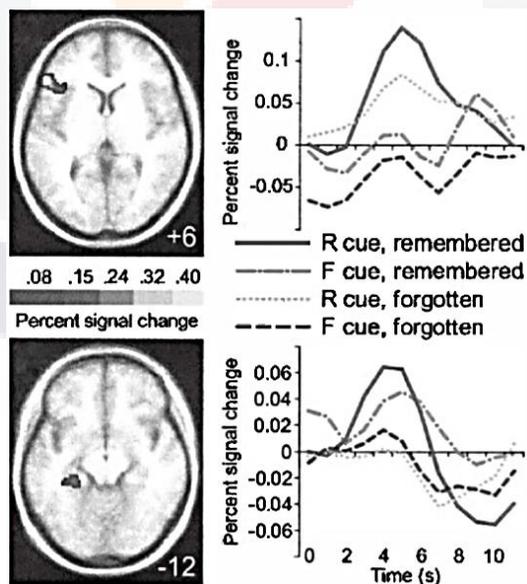


Figura 9 Activaciones funcionales de regiones prefrontal y medial temporal donde fueron predictivos del rendimiento de la memoria posterior. Se presentaron palabras simples, seguidas de una instrucción para recordar u olvidar (Sadock & Ruiz, 2015).

2.3 Ceguera.

Puesto que una de las dos poblaciones que se abarca en este estudio son las personas ciegas, se tratarán brevemente datos de importancia sobre la ceguera.

No se profundizará en las causas o tipos de problemas visuales que se presentan en la población, sino la situación sociodemográfica actual que enfrenta la ceguera.

De acuerdo con la Organización Mundial de la Salud (OMS), con arreglo a la Clasificación Internacional de Enfermedades (CIE-10, actualización y revisión de 2006), la función visual se subdivide en cuatro niveles (OMS, 2017):

- Visión normal.
- Discapacidad visual moderada.
- Discapacidad visual grave.
- Ceguera.

La discapacidad visual moderada y grave se reagrupan con el término “baja visión”, la cual, en conjunto con la ceguera, representan el total de casos de discapacidad visual (OMS, 2017). La ceguera se refiere a las condiciones caracterizadas por una limitación total o muy seria de la función visual. En específico, las personas con ceguera son aquellas que no pueden ver nada en absoluto o solamente tienen una ligera percepción de luz (ya que pueden ser capaces de distinguir entre luz y oscuridad, pero no la forma de los objetos) (ONCE, 2018)

En 2010, según datos de la OMS, el número estimado de personas con discapacidad visual en todo el mundo era cercano a 285 millones, de las cuales, 39 millones eran ciegas (OMS, 2017). Mientras tanto en México, según cifras del mismo año (2010), existían en el país 1,292,201 personas con limitación en actividades para ver (incluyendo a personas que aún con anteojos, tenían mucha dificultad para ver) (INEGI, 2019).

Una vez conocido el contexto de las personas con ceguera en nuestro país, ahora se abordará otro al otro tipo de usuarios, las personas con sobrecapacidad.

2.4 *Machine Learning* (Aprendizaje Automático).

Se abordará brevemente el tema sobre el Aprendizaje Automático (en inglés, *Machine Learning*) y otros temas a fines que sirven como herramienta para el análisis de datos (en este caso, un *dataset* compuesto de señales).

Entre las diferentes definiciones sobre *Machine Learning* se encuentran:

- Es el campo de estudio que da a las computadoras la habilidad de aprender sin ser explícitamente programadas (Francois, 2016).
- Problema de aprendizaje enfocado: Se dice que un programa de computadora aprende de la experiencia E con respecto a alguna tarea T y alguna medida de rendimiento P, si su rendimiento en T, medido por P, mejora con la experiencia E (Francois, 2016).

Los algoritmos de *Machine Learning* suelen ser divididos principalmente en dos categorías:

- ***Aprendizaje Supervisado:*** El algoritmo recibe datos de entrenamiento que contienen la “respuesta correcta” para cada ejemplo.
- ***Aprendizaje No Supervisado:*** El algoritmo busca la estructura de los datos e entrenamiento para encontrar que ejemplos son similares entre sí y agruparlos.

Otros autores también reconocen otro tipo de aprendizajes, como:

- ***Aprendizaje por refuerzo:*** el objetivo es aprender cómo mapear situaciones a acciones para maximizar una cierta señal de recompensa (Eduardo, 2019a).
- ***Aprendizaje semi-supervisado:*** El objetivo es tratar de combinar los datos no etiquetados con los etiquetados para construir un mejor clasificador debido a (Eduardo, 2019b):
 - la cantidad de datos no etiquetados disponibles y
 - el alto costo asociado a asignarles etiquetas

Otro concepto importante es identificar los tipos de problemas que se pueden atender con el aprendizaje automático (Francois, 2016):

- Regresión: Es un problema de aprendizaje supervisado donde la respuesta a aprender es un valor continuo.
- Clasificación: Es un problema de aprendizaje supervisado donde la respuesta a aprender es uno de los muchos valores posibles.
- Segmentación: Es un problema de aprendizaje no supervisado en el que la estructura a aprender es un conjunto de grupos de ejemplos similares.
- Análisis de redes: Es un problema de aprendizaje no supervisado donde la estructura a aprender es la información sobre la importancia y el papel de los nodos en la red.

Mediante la revisión de estos conceptos, se puede entender la importancia que tiene la aplicación de Aprendizaje Automático al proyecto de investigación.

2.5 Minería de Datos.

Siendo una de las ciencias computacionales que va más de la mano del *Machine Learning*, la Minería de Datos “*es el proceso de clasificación de grandes conjuntos de datos para encontrar información relevante y aprovechable para una finalidad específica. Como una subdisciplina de las ciencias de la informática, la minería de datos se centra fundamentalmente en patrones*” (Kaspersky, 2019).

Para (López, 2007), puede definirse como *un proceso de descubrimiento de nuevas y significativas relaciones, patrones y tendencias al examinar grandes cantidades de datos.* Según (Braga, Valencia, & Carvajal, 2009), la minería de datos “*está incluida en un proceso mayor denominado Descubrimiento del Conocimiento en Base de Datos, Knowledge Discovery in Database (KDD). Rigurosamente, el DM se restringe a la obtención de modelos, restando las etapas anteriores y el propio DM como instancias del KDD*” (Figura 10).

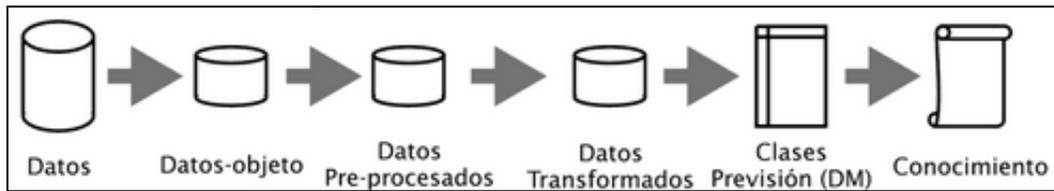


Figura 10 Esquema para la generación de conocimiento en bases de datos KDD (Braga et al., 2009).

El *Data Mining* puede usarse para (Kaspersky, 2019):

- Pronósticos y Riesgos
- Agrupamiento
- Análisis de Comportamiento

Desde la aproximación que se realiza en este trabajo de investigación, se puede considerar, que el uso de Minería de Datos está enfocado al Análisis de Comportamiento.

En este trabajo de investigación, se utiliza *WEKA*, *software* especializado en Minería de Datos, específicamente un algoritmo llamado *InfoGain*, que forma parte de la subrama de clasificación, la cual se muestra a continuación.

2.6 Sistemas Clasificadores.

La tarea de clasificación consiste en asignar objetos a una de varias categorías predefinidas a partir del análisis de sus atributos intrínsecos. Es un problema ampliamente diversificado y se extiende a varios campos de conocimiento tales como, por ejemplo, la detección de correos de spam a partir del texto del mensaje, la categorización de cardiopatías a partir de señales electrocardiográficas, la clasificación de galaxias a partir de su composición fotográfica (Figura 11).

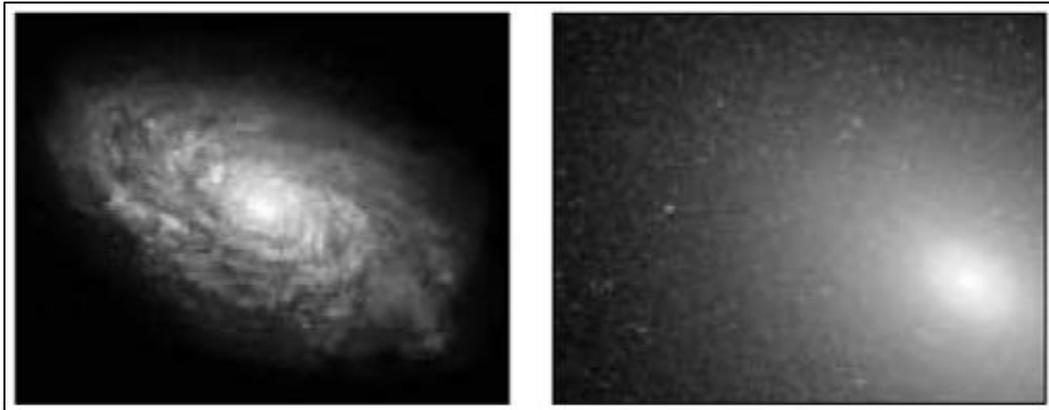


Figura 11 A la izquierda, una galaxia espiral, a la derecha, una galaxia elíptica (Tan, 2018).

Los algoritmos clasificadores deberán ser capaces de reconocer y extraer patrones a partir de los datos analizados, deben ser capaces de utilizar los datos previamente otorgados como datos de entrenamiento y además ser capaces de procesar datos nuevos sin un análisis previo.

Una primera aproximación sería definir un set de reglas que abarque cada una de las combinaciones de atributos con el conjunto de categorías. Sin embargo, el problema principal radica en la elevada cantidad de combinaciones de características posibles, por lo que definir reglas de inferencia (“if > then” por ejemplo) de forma empírica para cada una de ellas resulta impráctico.

Otra aproximación sería encontrar un modelo que explique de forma deductiva la manera como se generan los conjuntos de datos que determinan a cada uno de los objetos estudiados, sin embargo, aún carecemos del conocimiento necesario para definirlo y más aún para validarlo.

Por tal motivo, es mejor inclinarse entonces por otro enfoque al problema de clasificación bajo el esquema de aprendizaje máquina (*Machine Learning*), tratando el problema como una caja negra y bajo el principio del proceso inductivo de construcción.

2.6.1 Diseño de un algoritmo de clasificación.

Este enfoque del diseño de los sistemas clasificadores permite que su algoritmo general le permita inferir lógicamente, pero cuya funcionalidad dependa de la precisión de los datos

de entrenamiento (su lógica se construye sobre la veracidad de sus preceptos), por ejemplo, el uso de archivos previamente clasificados.

Las principales ventajas de este tipo de enfoque sobre aquellos basados en reglas son que no requieren de un experto que defina las reglas de clasificación y sobre todo que el dominio de los datos de entrenamiento es irrelevante (Estos se buscan encontrar de forma automática mediante el entrenamiento del sistema clasificador).

En la Figura 12 se muestra una aproximación para la construcción de un algoritmo de clasificación.

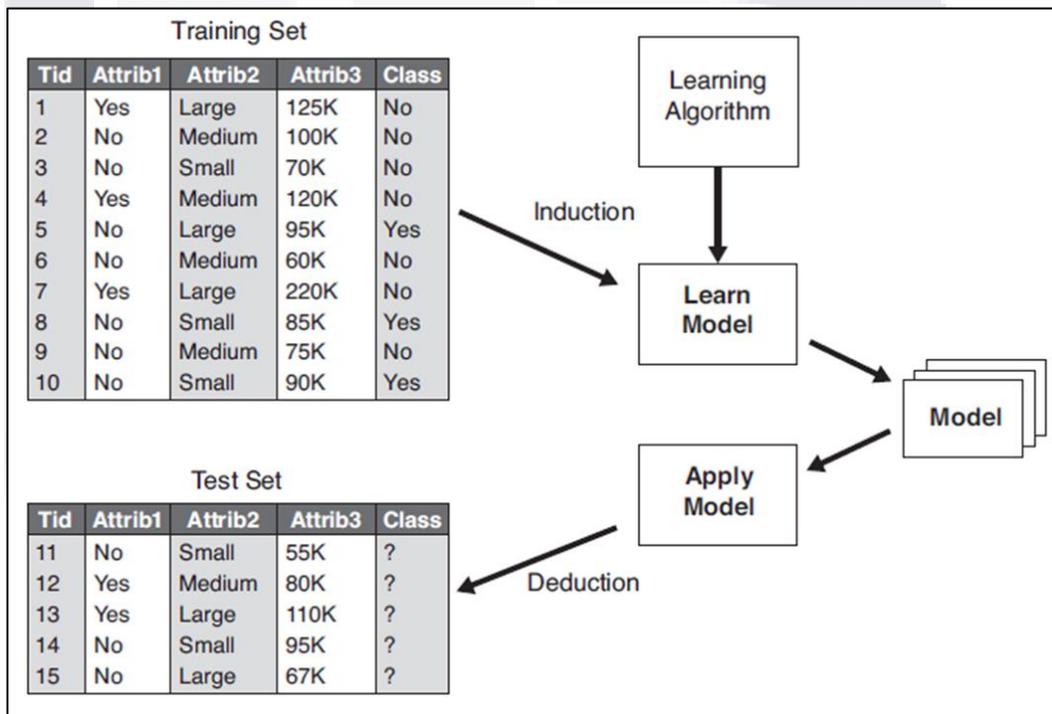


Figura 12 Aproximación para la construcción de un algoritmo de clasificación (Tan, 2018).

2.6.2 Proceso de clasificación.

Dado que un clasificador inductivo requiere que la validez de sus premisas sea correcta para clasificar correctamente, se necesita entonces información a priori del problema, datos de entrenamiento clasificados correctamente con anterioridad.

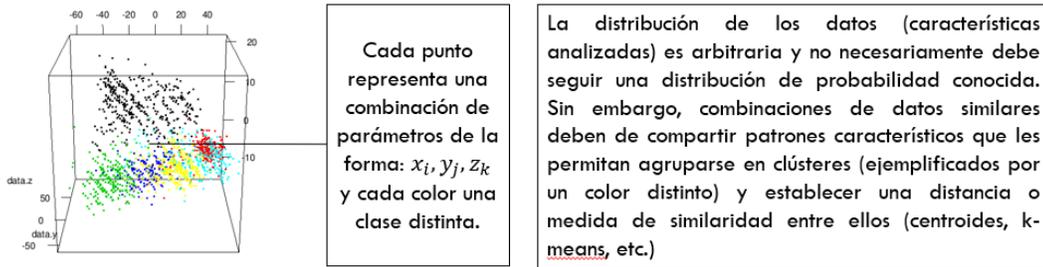


Figura 13 Proceso de clasificación (Cuéllar, 2018).

Se buscará entonces encontrar los umbrales que dividen a cada una de las clases (clústeres) (Figura 13) por medio de hiperplanos (estos se pueden construir a partir de una red neuronal o por medio de máquinas de soporte vectorial).

Existirán errores de clasificación (Figura 14, izquierda), correspondientes a objetos separados erróneamente por los hiperplanos. Para tal efecto es necesario entonces entrenar el algoritmo con respecto a la distribución de los datos (Figura 14, central), y ajustar los hiperplanos para una clasificación correcta (Figura 14, derecha).

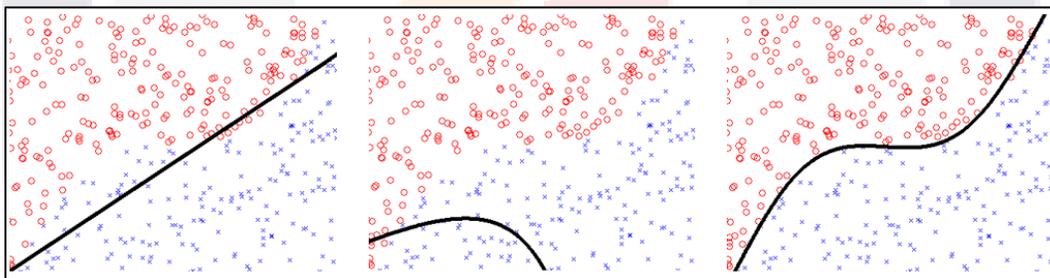


Figura 14 Errores en clasificación (Cuéllar, 2018).

Dicho entrenamiento se puede realizar de distintas formas, dependiendo del tipo de clasificador, por ejemplo, un algoritmo evolutivo, los cuáles han demostrado ser muy efectivos para tareas de clasificación ya que de forma implícita se ajustan a la distribución particular de los datos (aprendizaje del modelo).

Dicho ajuste corresponde con los parámetros de los algoritmos de clasificación, es decir, el número de capas, cantidad y pesos de las neuronas de una red neuronal o en el caso de las máquinas de soporte vectorial la definición y ajuste de los Kernels.

Al final se espera contar con un algoritmo entrenado que sea capaz de asignar una categoría correcta a cualquier conjunto de datos nuevos que se les presente, la probabilidad o proporción que represente el grado de pertenencia a cada categoría dependerá de la distancia de cada dato al hiperplano (Figura 15, derecha).

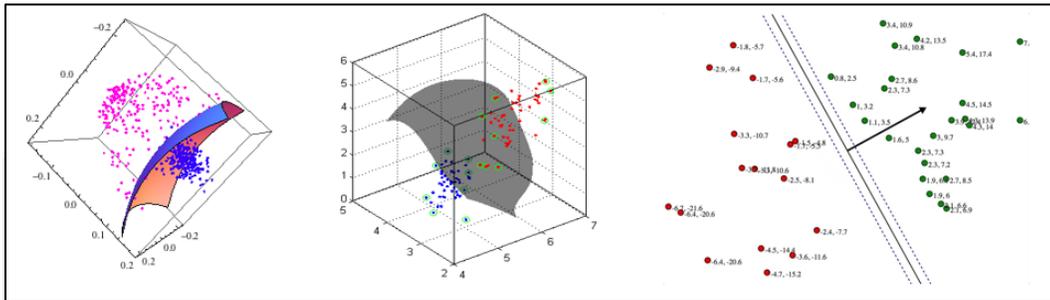


Figura 15 Ejemplo de clasificación (Cuéllar, 2018).

2.7 Ganancia de Información (*InfoGain*).

La Ganancia de Información, *Information Gain (InfoGain)* mide que tanta información un atributo (característica) da a una clase (Aguiar & Johnson, 2019):

- Los atributos que particionan perfectamente a la clase deberían proporcionar la máxima información.
- Los atributos no relacionados no deberían proporcionar información.
- Mide la reducción de la entropía. – Entropía: (im) pureza en una colección arbitraria de ejemplos.

La entropía, definida matemáticamente está definida como:

$$H = - \sum_{i=1}^K p_K \log_2 p_K \quad (1)$$

Así pues, la Ganancia de Información, que es el cambio en la Entropía, se define como:

$$\Delta H = H - \frac{m_L}{m} H_L - \frac{m_R}{m} H_R \quad (2)$$

Donde m es el número total de instancias, con m_k instancias pertenecientes a la clase k, donde K=1,...,k.

2.7.1 Ejemplo aplicado a un pequeño Dataset.

El siguiente es un ejemplo clásico sobre la decisión de jugar o no al tenis teniendo en cuenta ciertas condiciones climatológicas. Obtenido de (Aguiar & Johnson, 2019).

Tabla 1 Resultados sobre la predicción de jugar o no jugar tenis.

Outlook	Temperature	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Rainy	Cool	Normal	True	No
Overcast	Cool	Normal	True	Yes
Sunny	Mild	High	False	No
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes
Rainy	Mild	High	True	No

Los atributos del Dataset son:

Outlook: Panorama, perspectiva (climático).

Temperature; Temperatura.

Humidity; Humedad.

Windy: Ventosa. (Presencia de vientos).

Y la clase es:

Play: Jugar (Es decir, si se juega o no al tenis).

Dado que *InfoGain* es utilizado para la construcción de árboles de decisión, lo prioritario es verificar cuál de todos los atributos tiene una mayor ganancia de información, es decir, cuál de ellos divide mejor la clase (clasificación).

Nota:

Árbol de Clasificación: Es el esqueleto de un modelo de predicción que se suele representar en modo gráfico como un árbol en el que las ramas constituyen los patrones reconocidos en el proceso de aprendizaje. En las hojas de las ramas se situarían las predicciones para cada patrón (González, 2019).

Concerniente al ejemplo, como primer paso, se debe calcular la entropía según la clase:

$$H(Y) = - \sum_{i=1}^K p_K \log_2 p_K$$
$$= - \frac{5}{14} \log_2 \frac{5}{14} - \frac{9}{14} \log_2 \frac{9}{14} = 0.94$$

Tabla 2 Datos utilizados para el cálculo de la Entropía.

Outlook	Temperature	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Rainy	Cool	Normal	True	No
Overcast	Cool	Normal	True	Yes
Sunny	Mild	High	False	No
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes
Rainy	Mild	High	True	No

A manera de ejemplo, únicamente se calculará la Ganancia de Información del atributo *Humidity*:

$$\begin{aligned}
 \text{InfoGain}(\text{Humidity}) &= \\
 H(Y) &= H - \frac{m_L}{m} H_L - \frac{m_R}{m} H_R \\
 &= 0.94 - \frac{7}{14} H_L - \frac{7}{14} H_R
 \end{aligned}$$

Tabla 3 Datos utilizados para el cálculo del *InfoGain* de *Humidity*.

Outlook	Temperature	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Rainy	Cool	Normal	True	No
Overcast	Cool	Normal	True	Yes
Sunny	Mild	High	False	No
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes
Rainy	Mild	High	True	No

Para calcular H_L y H_R , se sigue:

$$H_L = -\frac{6}{7} \log_2 \frac{6}{7} - \frac{1}{7} \log_2 \frac{1}{7}$$

Tabla 4 Datos para el cálculo de H_L .

Outlook	Temperature	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Rainy	Cool	Normal	True	No
Overcast	Cool	Normal	True	Yes
Sunny	Mild	High	False	No
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes
Rainy	Mild	High	True	No

$$H_R = -\frac{3}{7} \log_2 \frac{3}{7} - \frac{4}{7} \log_2 \frac{4}{7} = 0.985$$

Tabla 5 Datos para el cálculo de Hr.

Outlook	Temperature	Humidity	Windy	Play
Sunny	Hot	High	False	No
Sunny	Hot	High	True	No
Overcast	Hot	High	False	Yes
Rainy	Mild	High	False	Yes
Rainy	Cool	Normal	False	Yes
Rainy	Cool	Normal	True	No
Overcast	Cool	Normal	True	Yes
Sunny	Mild	High	False	No
Sunny	Cool	Normal	False	Yes
Rainy	Mild	Normal	False	Yes
Sunny	Mild	Normal	True	Yes
Overcast	Mild	High	True	Yes
Overcast	Hot	Normal	False	Yes
Rainy	Mild	High	True	No

Así pues:

$$\begin{aligned}
 \text{InfoGain}(\text{Humidity}) &= \\
 H(Y) &= H - \frac{m_L}{m} H_L - \frac{m_R}{m} H_R \\
 &= 0.94 - \frac{7}{14} 0.592 - \frac{7}{14} 0.985 \\
 &= 0.94 - 0.296 - 0.4925 = 0.1515
 \end{aligned}$$

De manera similar y para todos los demás atributos:

$$Outlook = 0.247$$

$$Temperature = 0.029$$

$$Humidity = 0.152$$

$$Windy = 0.048$$

La división principal del árbol de decisión que se construiría mediante el *InfoGain* se hará así pues partiendo de “*Outlook*”, pues tiene la mayor Ganancia de Información (Figura 16).

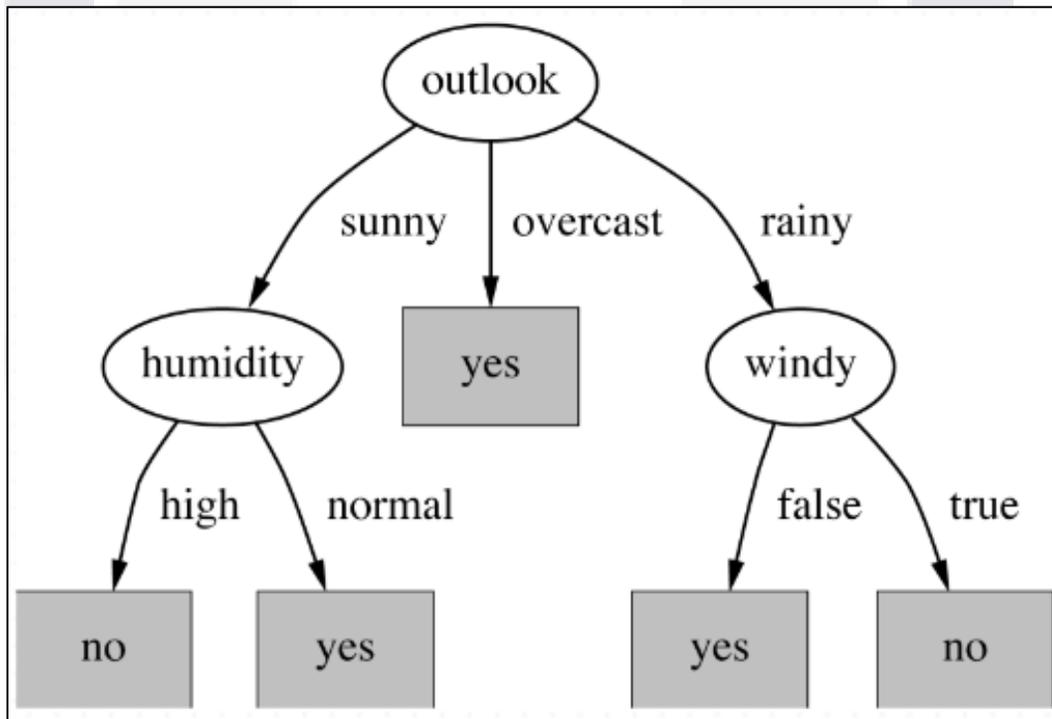


Figura 16 Árbol de Decisión generado a partir de la aplicación de *InfoGain*.

Capítulo III: Método de Investigación.

En esta sección se describe cada fase del proceso de investigación, dividido en dos etapas, la Planeación y la Ejecución con sus respectivos puntos, como se observa en la Figura 17.



Figura 17 Etapas del Método de Investigación.

3.1 Planeación

3.1.1 Metodologías de base y apoyo.

Puesto que medir aprendizaje o patrones de este mismo en señales EEG es una tarea compleja, el partir de experiencias previas de otros autores supone gran ayuda para no hacer una búsqueda sin rumbo. Por lo anterior, y a sabiendas que una de las características medibles más importantes (y fácilmente adquiribles con los *headsets* como *MindWave*

Mobile o *Emotiv EPOC* +) en el aprendizaje es la atención, esta investigación se centró en el análisis de este atributo mediante la aplicación de minería y ciencia de datos realizados en *WEKA*.

Así, pues, los trabajos que sirvieron de soporte a esta investigación se muestran a continuación.

En un estudio titulado “*Effects of Different Video Lecture Types on Sustained Attention, Emotion, Cognitive Load, and Learning Performance*” se miden diferentes parámetros relacionados con el aprendizaje en tres tipos diferentes de video educativos (W.-F. Wang, Chen, & Wu, 2015):

- *Voice-over videos*
- *Picture-in-picture videos*
- *Lecture Capture*

Los tres tipos de videos mejoran el rendimiento de aprendizaje, además:

- *Pic-in-Pic* logran mayor *Learning Performance*
- Carga cognitiva es mayor en *Voice-over videos*
- Atención sostenida es mayor en *Voice-over* que en *Pic-in-Pic*

En un artículo del Dr. Fu-ren Lin del *Institute of Service Science, National Tsing Hua University de Taiwan*, titulado *Mental Effort Detection Using EEG Data in E-learning Contexts* se construyó un sistema que “etiqueta” los estados mentales de participantes mientras que observan videos educativos de *YouTube* mientras se registran sus señales electroencefalográficas (Lin & Kao, 2018). En este mismo trabajo se demostró que el sujeto presta mayor atención cuando se trata de un tema de su interés.

En algunos otros trabajos, como “*Assessing the attention levels of students by using a novel attention aware system based on brainwave signals*” utilizan una video lectura (en este caso sobre seguridad eléctrica) como actividad de aprendizaje al momento de registrar las señales EEG de los participantes (Chen, Wang, & Yu, 2017).

3.1.2 Videos de divulgación científica como actividad de aprendizaje.

Con base en lo anterior, en este trabajo de investigación se utilizaron también videos educativos; el material audiovisual utilizado, fue descargado de YouTube del canal “*Date un Voltio*” de Javier Santaolalla, quien es un físico español que realiza videos de divulgación científica aptos para todo público. Los videos empleados se titulan:

- “*¿Cómo funciona el cerebro?*”
- “*La Tierra no gira en círculos alrededor del Sol*”
- “*¿Cómo surgió la vida en la Tierra?*”
- “*5 cosas que tal vez no sabías sobre nuestro universo*”.
- “*¿Qué pasaría si se invirtiera el campo magnético de la Tierra?*”

Con estas tareas (los videos de divulgación), se pretendió que los registros EEG de los participantes presentasen características con relaciones al aprendizaje y a la memoria, en este caso en concreto, y dado la duración del video, fluctuación en los niveles de atención, meditación, y/o aumento de algunas ondas cerebrales.

Se optó por utilizar cinco temas diferentes debido a que, como ya se mencionó, según el Dr. Fu-ren, el sujeto presta mayor atención cuando se trata de un tema de su interés (Lin & Kao, 2018). Cada video tiene una duración distinta, teniendo una duración mínima de 4:42 minutos y una duración máxima de 6:12 minutos.

3.1.3 Cuestionarios

Posterior a la video lección, independientemente de la elección del participante, se realizó un breve cuestionario escrito sobre el contenido del video (respectivo para cada video), consúltese Anexo A. Este tiene una duración máxima para responderlo de seis minutos, para no exceder un tiempo total de experimentación de aproximadamente doce minutos (aunque bien, el participante puede terminar el cuestionario antes).

Cabe mencionar, como nota importante, que, tanto en el video como en el cuestionario, se realizó el registro EEG de los participantes, sobre el cual, se realizaron los análisis.

3.1.4 Detección y trabajo con participantes.

Para llevar a cabo la experimentación se seleccionaron diez personas normovisuales. Puesto que en estudios similares se utiliza este mismo número de muestras o menos (Hu, Li, Sun, & Ratcliffe, 2016; Kober, Wood, Kampl, Neuper, & Ischebeck, 2014; Kriegseis, Hennighausen, Rösler, & Röder, 2006; Lancheros-Cuesta, Arias, Forero, & Duran, 2018). De las cuales, cinco de ellas fueron mujeres con un rango de edad de entre 22 – 45 años, así como también cinco hombres con las mismas características de edad. Las diez personas fueron seleccionadas en la Universidad Autónoma de Aguascalientes debido a que fue el lugar de experimentación, teniendo en su mayoría estudiantes de la universidad mencionada.

Mientras que, para la selección de personas ciegas se asistió al Centro de Desarrollo Integral de la Familia (DIF) del municipio de Aguascalientes y sólo se tomaron registros de cinco personas que se prestaron a colaborar con la experimentación. Tres de ellas fueron hombres con un rango de edad de entre 22 – 45 años, y el resto de las personas fueron mujeres con las mismas características de edad. La facilidad de trabajar con personas del DIF fue gracias al convenio de trabajo DG042_18 entre la UAA y esta entidad gubernamental.

Una vez descritas las consideraciones sobre la experimentación en cuanto a las video lecciones, cuestionarios y participantes, en la siguiente sección se aunará en los aspectos técnicos de la misma (*Hardware y Software*).

3.2 Ejecución.

3.2.1 Hardware utilizado.

Las herramientas de *hardware* que se utilizaron para la experimentación fueron dos laptops con un sistema operativo Windows 10 y procesador Intel Core i7 & i5: utilizando la de menor procesador para la reproducción del material audiovisual y la de mayor procesador para la adquisición de datos, la cual se realizó con un *Headset* de NeuroSky (Figura 10), *MindWave Mobile*, ya que esta cuenta con medición de atención. Además, se

utilizaron audífonos alámbricos para una mejor audición tal y como lo sugiere el trabajo presentado por el Dr. Fu-ren Lin.

Las características de adquisición del *Headset MindWave Mobile* son:

Salidas: de 12 bit Raw-Brainwaves (3 - 100Hz) con frecuencia de muestreo a 512Hz

Salidas: Espectros de poder (potencia de las señales EEG de las ondas *Alpha*, *Beta*, etc.)

Salidas: eSense de NeuroSky, como meditación, atención y parpadeo.

MindWave trabaja con sistemas operativos tales como *IOS*, *Windows XP*, o a partir de *Windows 7*. Cuenta con un sensor pasivo EEG seco y tecnología Bluetooth.

En la Figura 18 se muestra el modelo de la diadema utilizada:



Figura 18 *Headset MindWave Mobile* de NeuroSky (NeuroSky, 2015b)

3.2.2 Software para la adquisición

Para la adquisición y procesamiento de las señales se utilizaron los *softwares OpenViBE* y *WEKA*. El primero, cuenta con un módulo de adquisición y un módulo de procesamiento. En el apartado de adquisición se estableció la frecuencia de muestreo de

la señal a 512Hz y se establecieron las propiedades a obtener de la diadema (señal de atención, señal de meditación y potencia de las ondas *Delta*, *Theta*, *High Alpha* y *Low Alpha* y *High Beta* y *Low Beta*).

Mientras que, en el módulo de procesamiento, se creó un escenario como se muestra en la Figura 19 en el que mediante el uso de filtros pasa banda Butterworth de cuarto orden se clasificó la señal cruda del EEG con relación a sus frecuencias, (*Gamma* de 25 a 100Hz, *Beta* de 14 a 30Hz, *Alpha* de 8 a 13Hz, *Theta* de 4 a 7Hz, *Delta* de 0.5 a 3.5Hz).

Con la información proveniente del módulo de adquisición y procesamiento se creó una base de datos de cada participante, con los atributos: *Attention*, *Meditation*, potencia de las ondas *Delta*, *Theta*, *High Alpha*, *Low Alpha*, *High Beta*, *Low Beta* y las señales obtenidas mediante el uso de filtros.

Además, se creó un atributo extra al que se le nombró “Nivel de Atención”, este atributo clasifica los datos obtenidos de la señal de Atención en: Muy Mala, Mala, Regular, Buena y Muy Buena tomando en cuenta una escala de valores de 0 a 100, dividida en cinco partes iguales.

Para un recorrido detallado de *OpenViBE* y *WEKA*, consúltese el Anexo G.

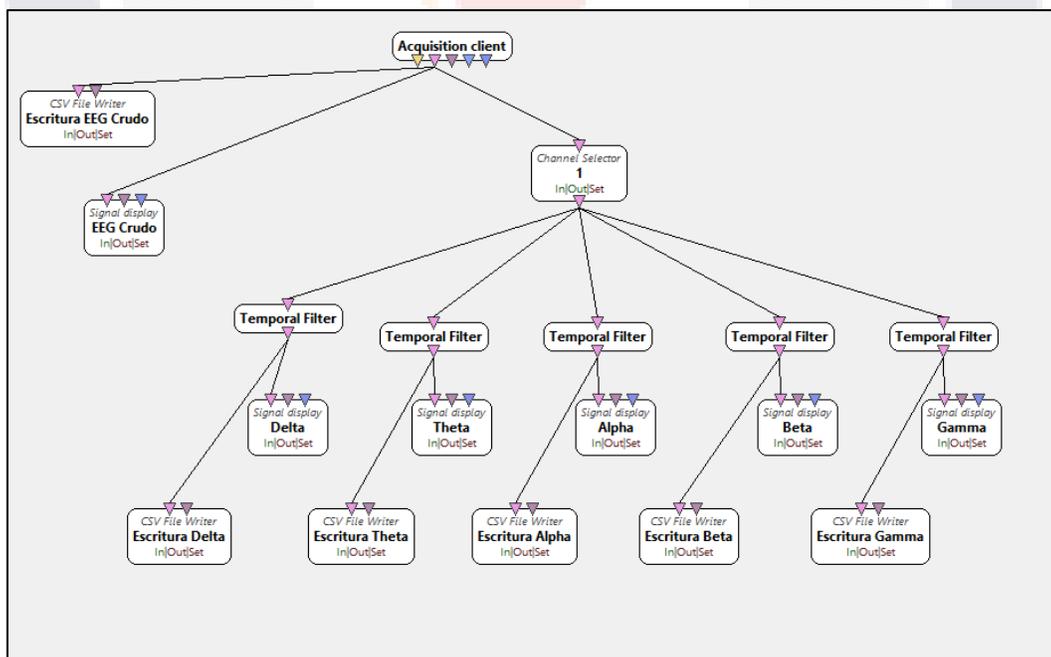


Figura 19 Arquitectura de procesamiento y registro de señales EEG.

3.2.3 Análisis en WEKA

Mediante la aplicación “*Explorer*” de *WEKA*, se cargaron los diferentes *datasets* de los participantes de la prueba. Como primer paso, se carga el *dataset* del participante, el cual consta de 18 atributos, los cuales se muestran en la Tabla 6.

Tabla 6 Atributos y su descripción del *DataSet*.

Nombre del Atributo	Descripción
<i>Time: 512Hz</i>	Tiempo, con frecuencia de muestreo a 512Hz
<i>Epoch</i>	Época
<i>Electrode</i>	EEG Crudo (<i>Raw</i>)
<i>Attention</i>	Nivel de Atención
<i>Meditation</i>	Nivel de Meditación
<i>Delta</i>	Densidad Espectral <i>Delta</i> (<i>Power Spectrum</i>)
<i>Theta</i>	Densidad Espectral <i>Theta</i>
<i>Low Alpha</i>	Densidad Espectral <i>Alpha</i> Baja
<i>High Alpha</i>	Densidad Espectral <i>Alpha</i> Alta
<i>Low Beta</i>	Densidad Espectral <i>Beta</i> Baja
<i>High Beta</i>	Densidad Espectral <i>Beta</i> Alta
<i>Low Gamma</i>	Densidad Espectral <i>Gamma</i> Baja
<i>Mid Gamma</i>	Densidad Espectral <i>Gamma</i> Media
<i>Delta Signal</i>	<i>Delta</i> (Señal)
<i>Theta Signal</i>	<i>Theta</i> (Señal)
<i>Alpha Signal</i>	<i>Alpha</i> (Señal)
<i>Beta Signal</i>	<i>Beta</i> (Señal)
<i>Gamma Signal</i>	<i>Gamma</i> (Señal)

Para una descripción más a fondo del contenido de un *Dataset* generado en esta investigación, consúltese el Anexo C.

WEKA sirvió para obtener el promedio de los valores de los niveles Atención y su respectivo histograma, esto con la finalidad de tener un análisis visual de los datos de cada participante.

También se implementó la herramienta *InfoGain* que sirve para medir la ganancia de Información de cada Atributo, tomando el Atributo “Nivel de Atención” como “clase”. Esta herramienta arroja un rango de valores para cada atributo ordenándolos de mayor a menor. Este algoritmo es utilizado en la construcción de árboles de decisiones debido a que su propósito principal es determinar la relevancia de un atributo y, por lo tanto, su

orden en el árbol de decisiones (Ceri et al., 2003). Es por lo que en este proyecto esta herramienta sirvió para cuantificar la incidencia de las ondas de frecuencia del EEG en la clasificación de niveles de atención.

Se tomaron en cuenta los cinco atributos que mostraron los valores de ganancia de información más altos de cada participante, para así crear una base de datos en *Excel* para personas normovisuales y ciegas e identificar el patrón de a de atributos con mayor incidencia en las dos poblaciones estudiadas.

3.2.4 Entorno del experimento

El experimento con personas normovisuales se realizó en el “Laboratorio de Industria de *Software*”, ubicado en el edificio 204 de la Universidad Autónoma de Aguascalientes. En dicho laboratorio, el participante tuvo a su disposición una silla cómoda y de altura ajustable, así como también un espacio libre de distracciones. Mientras que, para las personas ciegas el estudio se realizó en las instalaciones del DIF en la “Sala Inclusiva”, y en condiciones similares al de las personas normovisuales. En ambos casos mediante la Carta de Consentimiento Informado (Anexo B) se les pidió su autorización para ser videograbadas.

3.2.5 Desarrollo del experimento

El modelo de experimentación utilizado constó de tres fases como lo muestra la Figura 20. La primera fase consistió en la preparación técnica y del participante. Es decir, se le explicó a cada participante en qué consistía el experimento, se les pidió que leyeran o escucharan atentamente (de acuerdo con las condiciones del participante) y firmaran la Carta de Consentimiento Informado (Anexo B) en donde se encontraban detalladamente las instrucciones a seguir para realizar el experimento y la especificación de la confidencialidad de los datos. Posterior a esto, se les preguntó sobre posibles dudas. Una vez aclaradas las dudas e informado el participante, se le colocó la diadema *MindWave Mobile* y los auriculares. En cuanto a los aspectos técnicos, se preparó el video y se les pidió ajustaran el volumen a su preferencia, además se estableció la conexión entre la diadema y la laptop en donde se adquirió el registro del EEG. El tiempo empleado en esta primera fase fue de un aproximado de cinco minutos.

La segunda fase constó de la reproducción del material audiovisual elegido de acuerdo con la preferencia del participante. Una vez establecida la conexión entre la diadema *MindWave Mobile* con la segunda computadora, se le pidió al participante que mantuviera los ojos cerrados y tratara de relajarse durante treinta segundos, con la finalidad de obtener un registro del estado basal del sujeto en periodo de relajación (Lin & Kao, 2018). Concluido este tiempo, el sujeto oprimió la tecla espaciadora para reproducir el video. Durante esta fase, se inició con la adquisición datos del EEG del sujeto. El procedimiento duró un aproximado de siete minutos.

En la tercera fase el participante procedió a resolver de manera verbal un cuestionario que constaba de cinco preguntas pregrabadas, relativas al video previamente visto o escuchado según fuera el caso (Anexo A). El registro de datos del EEG terminó cuando el participante finalizó con la respuesta del cuestionario.

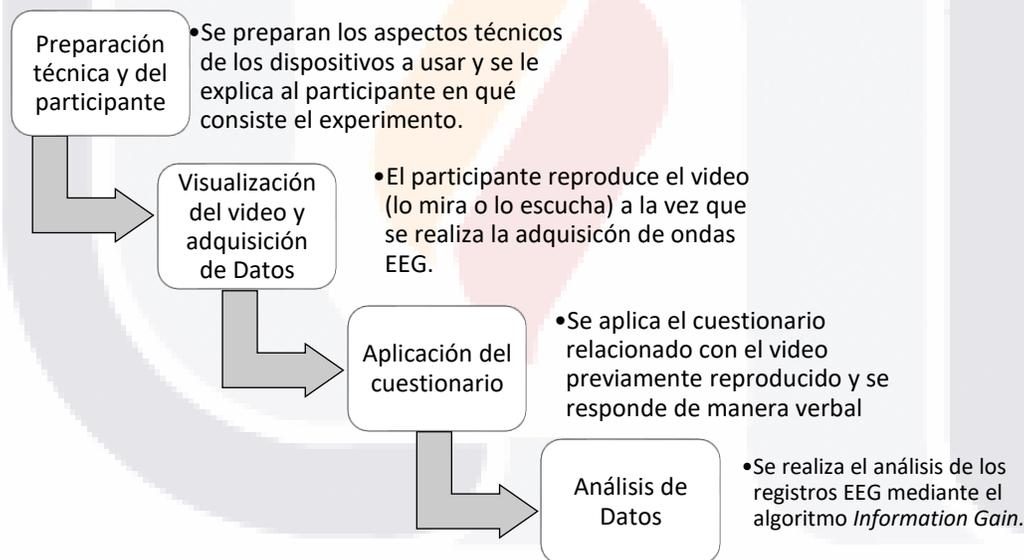


Figura 20 Fases de la Experimentación

3.3 Comparación con los casos de estudio.

Con una aproximación muy diferente, en el Experimento del Anexo 8, se exponen también mediciones iniciales de Aprendizaje Explícito e Implícito. Llevadas a cabo con un *software* diferente, llamado *Neuro Experimenter*, pero utilizando también el *MindWave Mobile* con un diseño experimental y ejecución más simple.

Además de lo anterior, en el Experimento 2 del mismo Anexo, únicamente para llevar a cabo otro tipo de análisis mediante una herramienta de *WEKA* llamada *CfsSubSetEval*, se exponen mediciones iniciales de registros EEG con una metodología similar, con una única video lección y con solo cuatro participantes normovisuales.

Cabe señalar que ambas experimentaciones previas, ayudaron a dar forma al diseño experimental y análisis definitivo utilizado en la tesis.

Por ejemplo, mediante la primera aproximación, en la cual se trataba de realizar un análisis directo en la forma de la señal (tratando de identificar los cambios de ritmo en las sincronías alfa-beta), se llegó a la conclusión de que este tipo de análisis no resultaba tan efectivo, además que el dominio y conocimiento que se tenía para ese entonces con las herramientas de adquisición y procesamiento no era el más adecuado.

Si bien, mediante esta aproximación no se llegaron a resultados concluyentes, sí sirvió para tener en claro que se tenían que hacer ajustes en la calidad de los datos, registro y procesamiento, así como un cambio de enfoque en el diseño experimental y el análisis.

Así pues, en el Experimento 2, se realiza un cambio completo en el paradigma, ahora utilizando una aproximación orientada a la clasificación mediante algoritmos de *Machine Learning* utilizando *software* especializado en Adquisición y Procesamiento de EEG (*OpenViBE*) y *software* para Minería de Datos (*WEKA*), así como en el diseño experimental, garantizando principalmente, la calidad de los datos.

Debido a la limitante de la cantidad de participantes que pudieron colaborar en ese proyecto, únicamente se realizaron pruebas con cuatro sujetos normovisuales, pero la aplicación de un algoritmo como *CfsSubSetEval*, abrió el camino al análisis de asociación de atributos hacia una clase, procedimiento que más tarde sirvió para dar con un algoritmo más efectivo para dicha tarea, el *Information Gain*.

Capítulo IV: Resultados.

En este capítulo se presentan los resultados obtenidos luego de haber aplicado la metodología anterior. Se muestran, por motivos de simplicidad, únicamente los resultados de los dos primeros participantes ciegos y los dos primeros normovisuales.

Para observar los histogramas y las tablas de datos de los participantes de ambos grupos, consúltese el Anexo D.

Además, para observar las gráficas de los niveles de Atención de los participantes, basados en esta misma metodología, consúltese el Anexo E.

Por último, para observar la relación del nivel de atención con los niveles de las ondas Beta Baja y Beta Alta de cada participante, consúltese el Anexo F.

4.1 Histogramas de Atención y Datos de los participantes.

4.1.1 Participantes ciegos

Participante 1

Tabla 7 Datos del Participante Ciego 1.

Edad	37
Sexo	Mujer
Elección de video	<i>5 cosas que tal vez no sabias sobre nuestro universo</i>
Preguntas correctas	2
Atención promedio	53.33

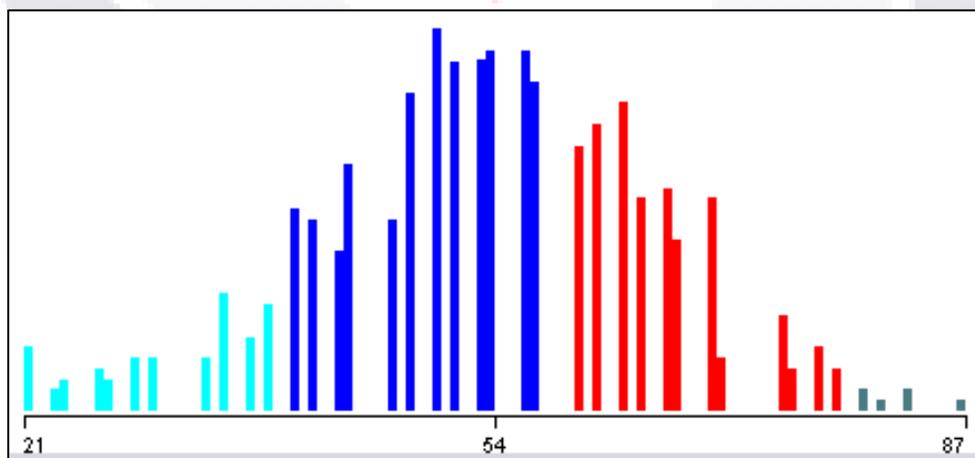


Figura 21 Histograma de Atención del Participante Ciego 1.

Participante 2

Tabla 8 Datos del Participante Ciego 2.

Edad	43
Sexo	Hombre
Elección de video	<i>¿Cómo surgió la vida en La Tierra?</i>
Preguntas correctas	3
Atención promedio	49.139

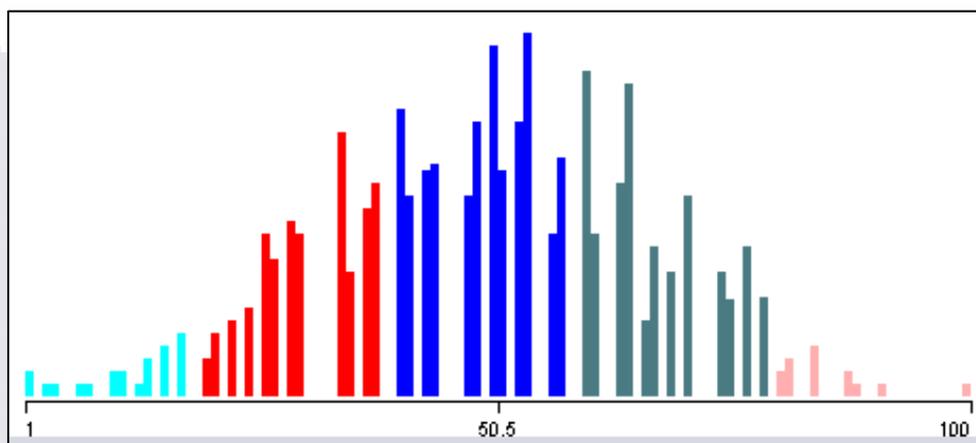


Figura 22 Histograma de Atención del Participante Ciego 2.

4.1.2 Participantes Normovisuales

Participante 1.

Tabla 9 Datos del Participante Normovisual 1.

Edad	23
Sexo	Mujer
Elección de video	<i>¿Cómo funciona el Cerebro?</i>
Preguntas correctas	5
Atención promedio	45.48

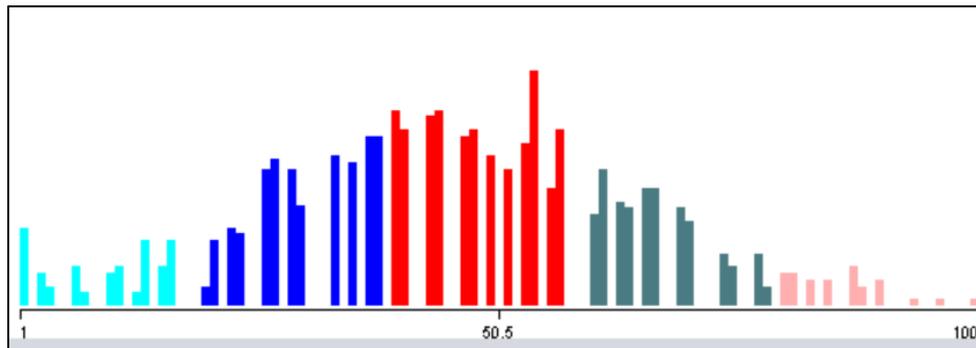


Figura 23 Histograma de Atención del Participante Normovisual 1.

Participante 2.

Tabla 10 Datos del Participante Normovisual 2.

Edad	21
Sexo	Mujer
Elección de video	<i>¿Cómo surgió la vida en la tierra?</i>
Preguntas correctas	4
Atención promedio	52.7

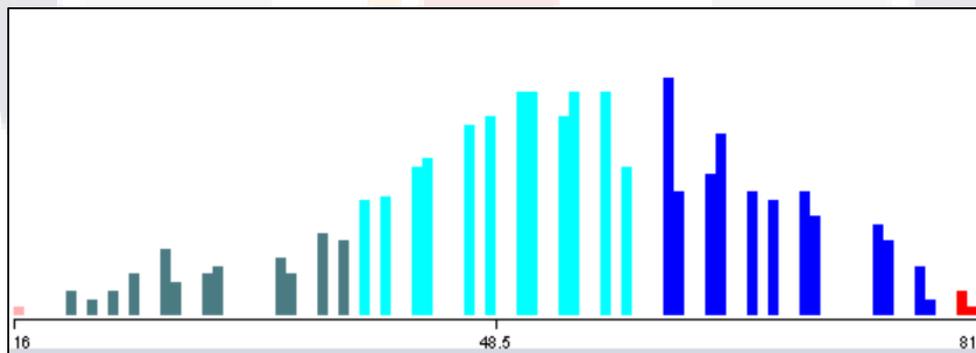


Figura 24 Histograma de Atención del Participante Normovisual 2.

4.2 Gráficas de Atención

Si bien, no se trabaja directamente sobre el atributo “*Attention*”, la clase, “Nivel de Atención” sí se generó a partir de este, por lo cual, es interesante observar el comportamiento de este durante la realización de la experimentación, comprobando si existiesen fluctuaciones importantes o un comportamiento similar.

Cabe señalar que *WEKA* automáticamente asignó los colores, por lo que no hay homogeneidad en las gráficas con respecto a todos los participantes, pero la clasificación sigue siendo la misma:

En orden ascendente:

- Atención ≤ 20 -----Muy Mala
- Atención >20 y ≤ 40 ----Mala
- Atención >40 y ≤ 60 ----Regular
- Atención >60 y ≤ 80 ----Buena
- Atención <80 -----Muy Buena

4.2.1 Participantes ciegos

Participante 1.

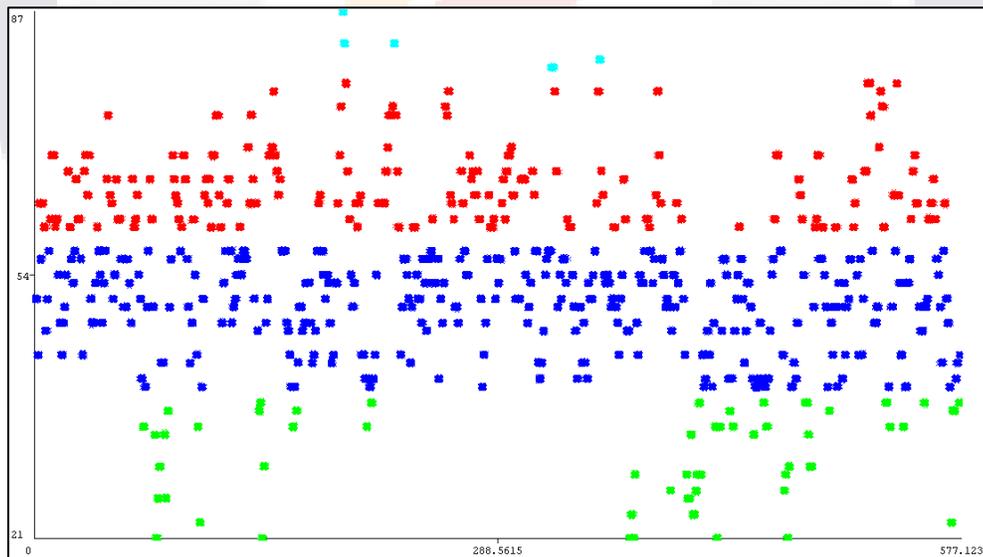


Figura 25 Gráfica de Atención del participante ciego 1.

Participante 2.

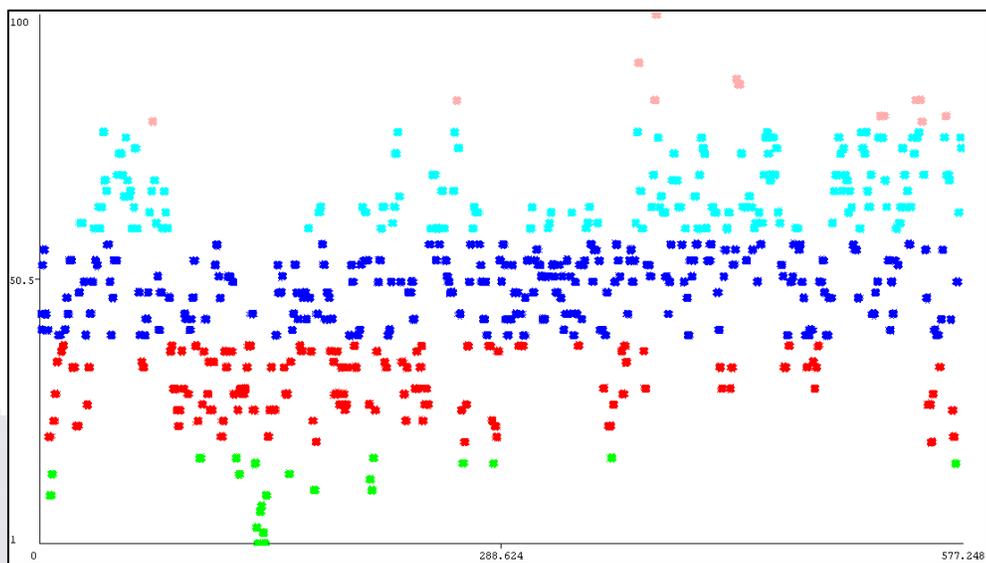


Figura 26 Gráfica de Atención del participante ciego 2.

4.2.2 Participantes normovisuales

Participante 1:

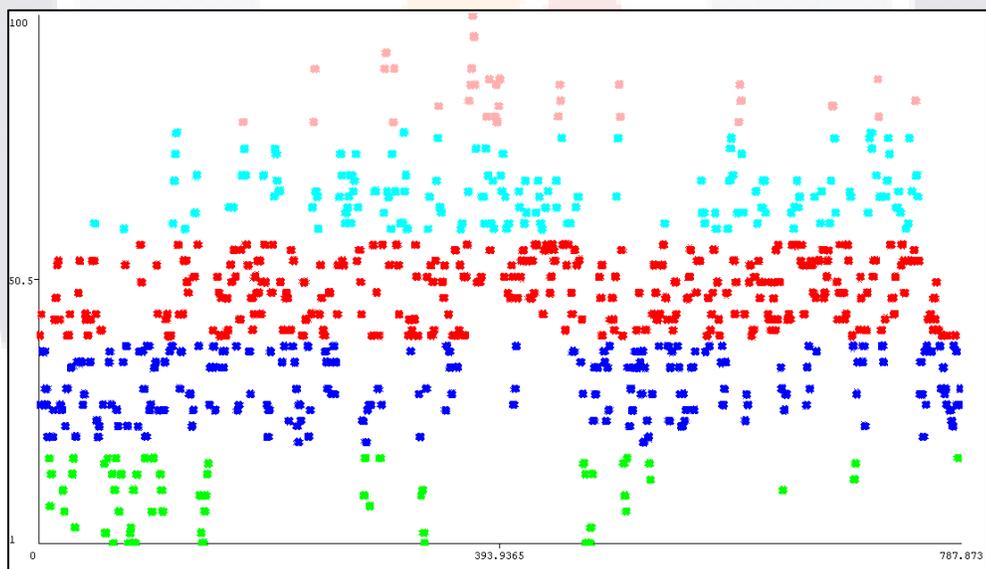


Figura 27 Gráfica de Atención del participante normovisual 1.

Participante 2:

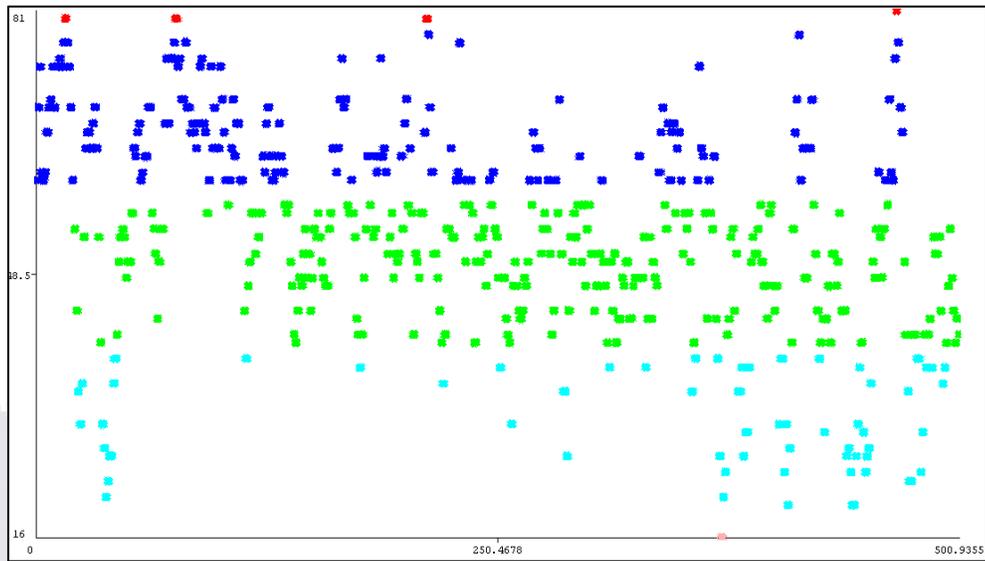


Figura 28 Gráfica de Atención del participante normovisual 2.

4.3 Relación del Nivel de Atención con los niveles *Low Beta* y *High Beta* de cada participante.

La onda *Beta*, situada por encima de la onda *Alpha* y antes que la onda *Gamma*, es la más relacionada con la atención, por lo cual, en esta sección se muestran las gráficas de las potencias *Beta* Baja y Alta con relación a la atención de cada participante de ambos grupos (normovisuales y ciegos). Los atributos han sido normalizados para garantizar una homogeneidad en las escalas de las gráficas.

El Eje X representa al atributo “*Attention*”, mientras que el Eje Y corresponde a “*Low Beta*” o “*High Beta*”.

4.3.1 Participantes ciegos

Participante 1.

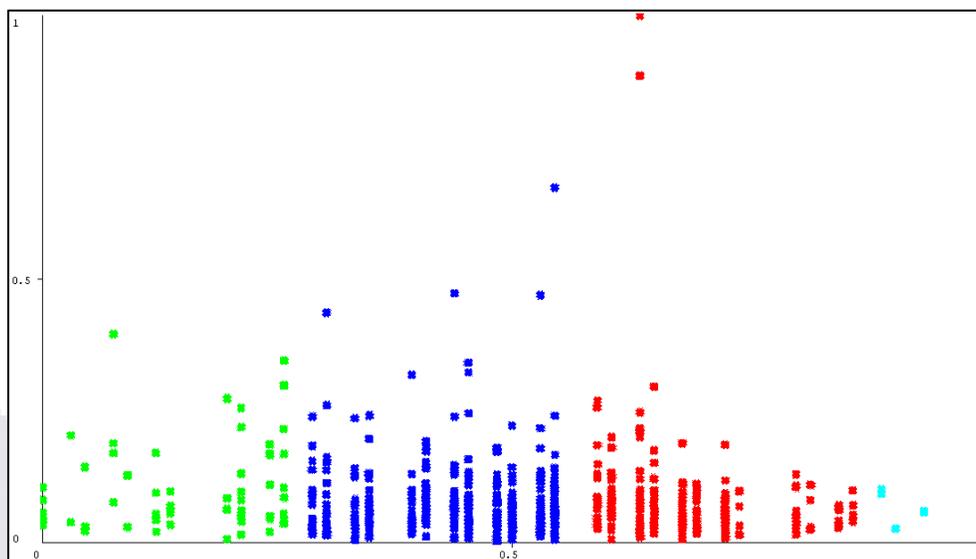


Figura 29 Gráfica de *Low Beta* del participante ciego 1.

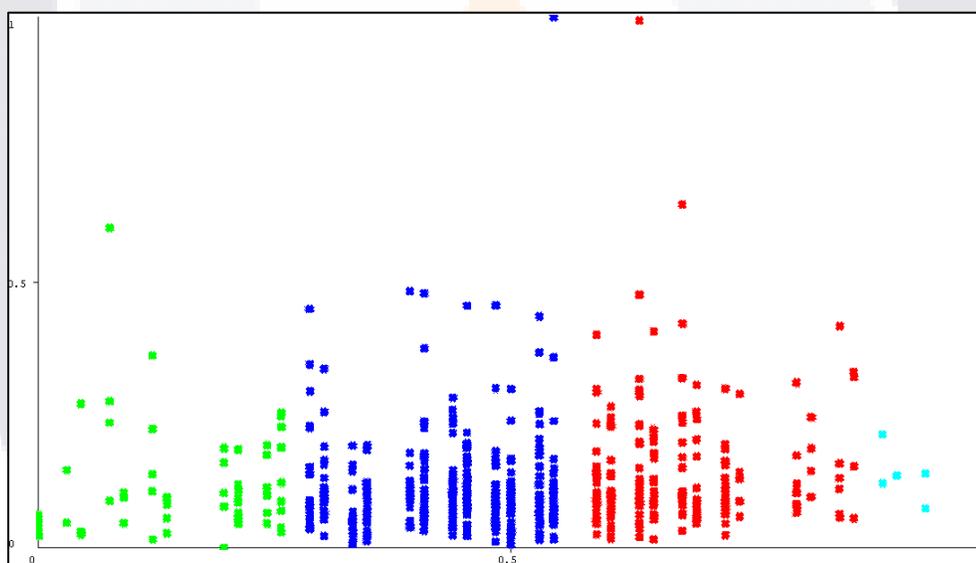


Figura 30 Gráfica de *High Beta* del participante ciego 1.

Participante 2.

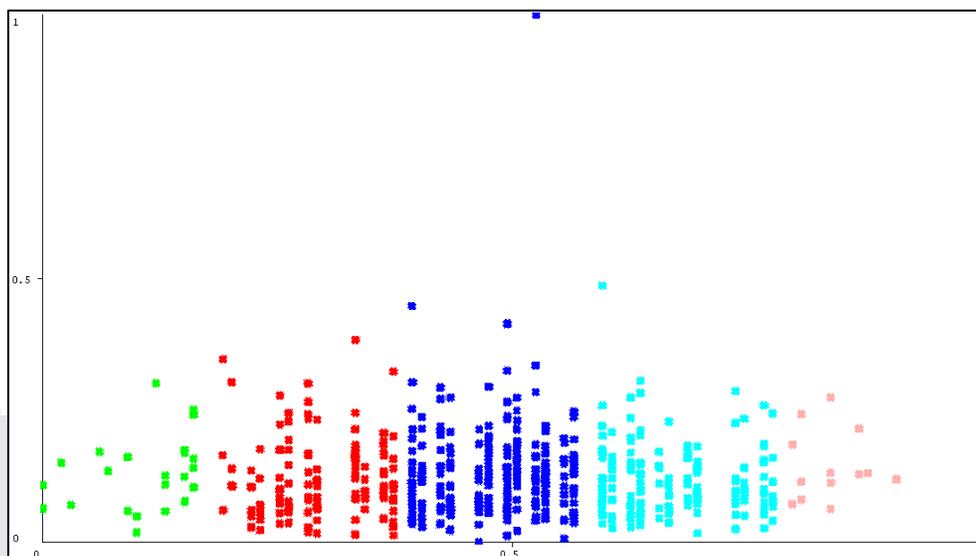


Figura 31 Gráfica de *Low Beta* del participante ciego 2.

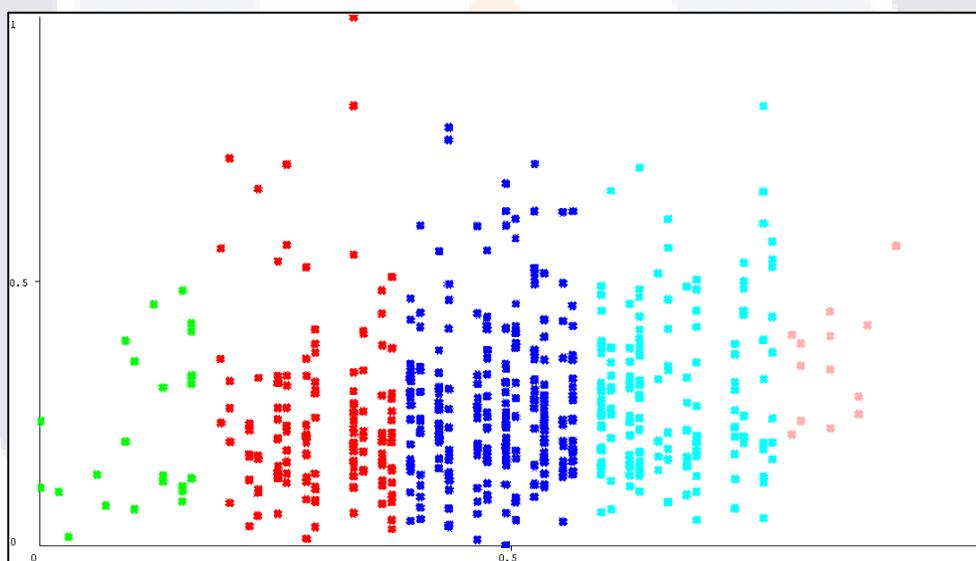


Figura 32 Gráfica de *High Beta* del participante ciego 2.

4.3.2 Participantes normovisuales

Participante 1.

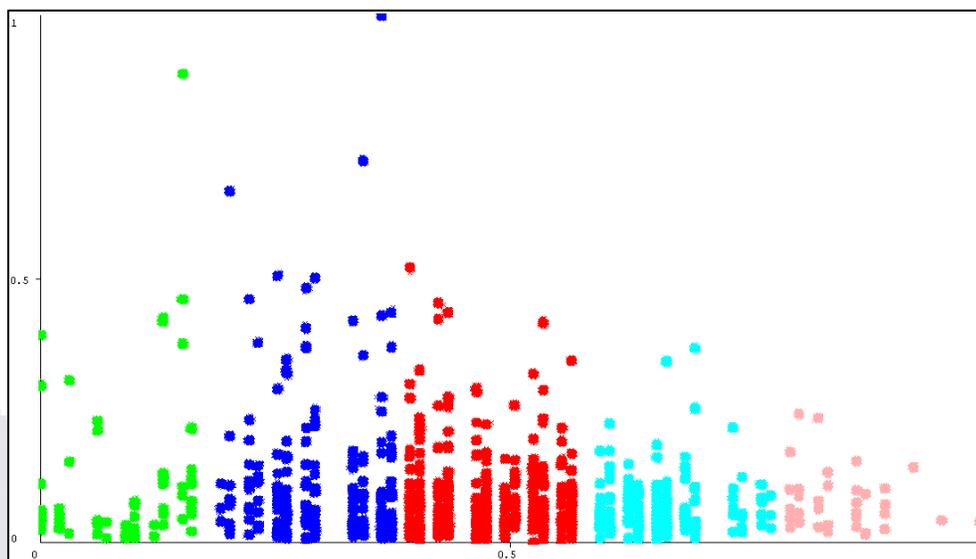


Figura 33 Gráfica de Low Beta del participante normovisual 1.

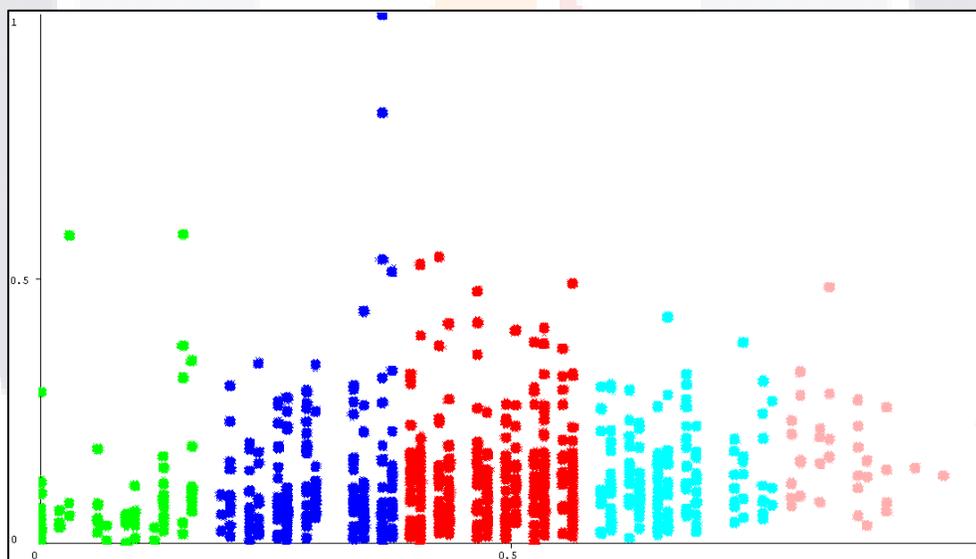


Figura 34 Gráfica de High Beta del participante normovisual 1.

Participante 2.

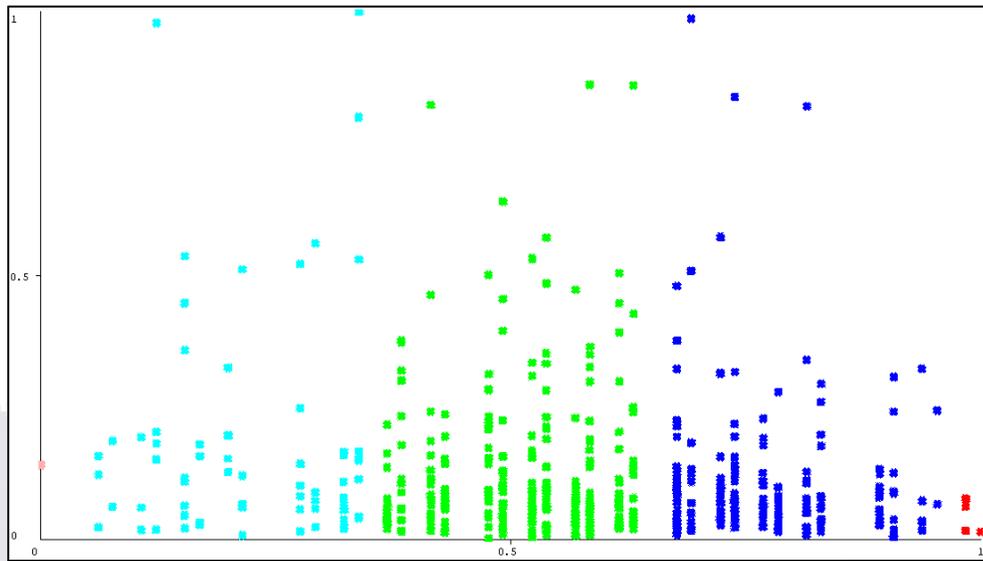


Figura 35 Gráfica de Low Beta del participante normovisual 2.

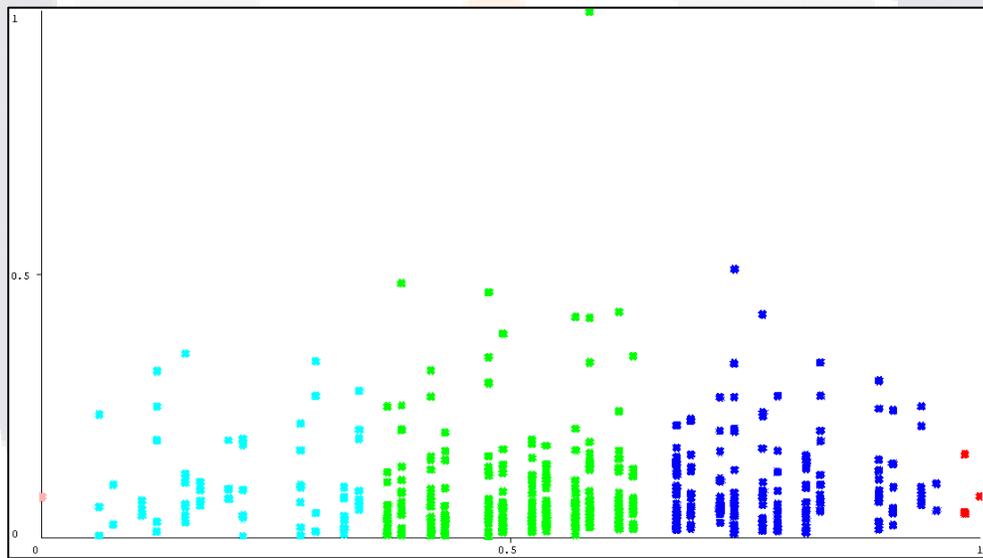


Figura 36 Gráfica de High Beta del participante normovisual 2.

4.4 Aplicación de Ganancia de Información (*InfoGain*)

Tabla 11 Resultados de la aplicación de *InfoGain* a la clase “Nivel de Atención” en los *datasets* de los participantes ciegos.

Participante 1	Participante 2	Participante 3	Participante 4	Participante 5
1.40503 <i>Delta</i>	1.8462 <i>Theta</i>	1.91067 <i>Attention</i>	2.12953 <i>Attention</i>	2.000122 <i>Delta</i>
1.40503 <i>Theta</i>	1.8462 <i>Delta</i>	1.90714 <i>Delta</i>	2.12562 <i>Delta</i>	2.000122 <i>Attention</i>

1.40503 <i>Attention</i>	1.8462 <i>Attention</i>	1.89652 <i>Low</i> <i>Alpha</i>	2.11779 <i>Low</i> <i>Beta</i>	1.99679 <i>High</i> <i>Alpha</i>
1.39463 <i>Low</i> <i>Beta</i>	1.842732 <i>High Alpha</i>	1.88588 <i>Theta</i>	2.11778 <i>Low</i> <i>Alpha</i>	1.996787 <i>Theta</i>
1.39118 <i>Low</i> <i>Alpha</i>	1.839268 <i>Low</i> <i>Alpha</i>	1.88237 <i>High</i> <i>Alpha</i>	2.11387 <i>Theta</i>	1.990138 <i>Low</i> <i>Alpha</i>

Tabla 12 Resultados de la aplicación de *InfoGain* a la clase “Nivel de Atención” en los *datasets* de los participantes normovisuales.

Participante 1	Participante 2	Participante 3	Participante 4	Participante 5
1.99777 <i>Attention</i>	1.47878 <i>Attention</i>	1.93513 <i>Attention</i>	1.92641 <i>Attention</i>	1.827816 <i>Attention</i>
1.99777 <i>Delta</i>	1.47878 <i>Theta</i>	1.93182 <i>Theta</i>	1.92641 <i>Low</i> <i>Alpha</i>	1.827816 <i>Delta</i>
1.99269 <i>Theta</i>	1.47479 <i>Low</i> <i>Beta</i>	1.93182 <i>Delta</i>	1.9225 <i>Delta</i>	1.824356 <i>Theta</i>
1.99015 <i>Low</i> <i>Alpha</i>	1.47479 <i>Delta</i>	1.9252 <i>Low</i> <i>Alfa</i>	1.91468 <i>Theta</i>	1.824356 <i>High Alfa</i>
1.99015 <i>High</i> <i>Beta</i>	1.47479 <i>High</i> <i>Alfa</i>	1.92188 <i>High</i> <i>Beta</i>	1.91468 <i>High</i> <i>Beta</i>	1.810523 <i>Low Alpha</i>
Participante 6	Participante 7	Participante 8	Participante 9	Participante 10
1.8915 <i>Theta</i>	1.555775 <i>Attention</i>	2.10526 <i>Delta</i>	2.2544 <i>Attention</i>	1.22772 <i>Theta</i>
1.8915 <i>Attention</i>	1.55575 <i>Theta</i>	2.10526 <i>Attention</i>	2.2544 <i>Delta</i>	1.22772 <i>Delta</i>
1.8915 <i>High</i> <i>Alpha</i>	1.55575 <i>Delta</i>	2.09879 <i>High</i> <i>Alpha</i>	2.25019 <i>Low</i> <i>Alpha</i>	1.22772 <i>Attention</i>
1.8883 <i>Delta</i>	1.55575 <i>High</i> <i>Beta</i>	2.09878 <i>Theta</i>	2.25019 <i>High</i> <i>Beta</i>	1.22442 <i>Low Alpha</i>
1.8883 <i>Low Beta</i>	1.55171 <i>Low</i> <i>Alpha</i>	2.09556 <i>Low</i> <i>Beta</i>	2.24599 <i>Low</i> <i>Beta</i>	1.22441 <i>High Beta</i>

Discusión de Resultados.

Interpretación de los Histogramas y las Tablas de Datos de los participantes.

En general, para ambos grupos, el promedio de atención según se observa en los Histogramas, estuvo alrededor del 50.

De hecho, si se calcula la media de medias a partir de las Tablas únicamente de estos cuatro participantes (dos ciegos y dos normovisuales), el resultado es 50.162, lo que indica un Nivel de Atención sumamente Regular con base en la escala propuesta.

Al promediar los datos de todos los participantes ciegos, su Nivel de Atención promedio fue de 41.0804, mientras que para normovisuales fue de 51.7644; en conjunto, el de ambos grupos fue 46.4224, hallándose también en “Regular”.

Ahora bien, en cuanto a la elección del video de divulgación científica más elegido, “¿Cómo surgió la vida en la Tierra?” y “¿Cómo funciona el cerebro?” fueron los que principales.

Si se desea consultar a detalle los Histogramas y Tablas de datos de los demás participantes, consúltese el Anexo D.

Interpretación de las gráficas de Atención de los participantes

Participante ciego 1.

El nivel de atención promedio fue 53.33, es decir, “Regular”, como se observa en su registro, donde la mayormente se observan muestras en este nivel. Una peculiaridad de este participante es que jamás llegó a presentar niveles de atención menores a 21, por lo que nunca llegó a una atención “Muy Mala”. De manera similar, el límite superior llegó a 87, además de presentar por muy pocos momentos niveles de atención “Muy Buena”.

Participante ciego 2.

Este participante pasó la mayor parte de la experimentación entre los niveles “Malo”, “Regular” y “Bueno”, lo que explica que su nivel de atención promedio fuera de 49.139, es decir, “Regular”, prácticamente en 50, con niveles “Muy Malos” un poco presentes y “Muy Buenos” prácticamente ausentes.

Participante normovisual 1.

La mayor parte de la prueba registra niveles de atención de “Malos” a “Regulares”, alcanzando en algunas ocasiones niveles “Buenos” y escasamente “Muy buenos”. Su nivel de atención promedio durante la prueba fue de 45.487

Participante normovisual 2.

Con él, ocurrió que su nivel de atención durante la experimentación nunca rebasó el 81, por lo cual, al no llegar más alto, la escala no supera este punto. Al igual que al límite inferior, nunca bajó más allá de 16, por lo cual la escala se ajusta a este valor. Su nivel promedio de atención fue de 52.7, bastante “Regular”, tanto así que, de hecho, los puntos de atención máxima y mínima son muy escasos.

Aplicación del algoritmo de análisis *InfoGain*.

Bajo este entorno de experimentación, se puede concluir que tanto ciegos como normovisuales presentan características similares en su análisis de EEG presentando señales *Delta*, *Theta* y *Attention* (sin gran diferencia entre magnitud entre sí), con la diferencia de que las personas normovisuales además de presentar las ya mencionadas señales, también presentan potencias de ondas *High Beta* por lo que sugiere que los algoritmos para evaluar la atención en entornos de aprendizaje podrían funcionar tanto en personas normovisuales como ciegas.

En cuanto a la magnitud, el promedio de los atributos más altos para cada grupo tampoco muestra gran diferencia, siendo 1.8583 para ciegos y 1.82005 para normovisuales.

Sin embargo, es necesario realizar estudios con un mayor número de participantes, puesto que no es una conclusión contundente. Es por ello por lo que se pretende en un futuro, trabajar con un número de participantes mayor y seguir analizando dichos patrones además de mejorar el entorno de experimentación, buscando entornos más próximos a la cotidianidad.

Interpretación de la relación de las ondas *Low Beta* y *High Beta* con el Nivel de Atención.

Si bien, pareciera que las gráficas no dicen mucho, puesto que siguen cierta aleatoriedad, la realidad es que, la atención se centra en amplitudes bajas de las ondas Beta (No

importando si fue “Muy Mala” o “Muy Alta” atención). Es decir, para la gran mayoría de los participantes, ciegos y normovisuales, la mayoría de la atención se encuentra en rangos pequeños de “*Low Beta*” y “*High Beta*”.

Comparación con los casos de estudio

Como se mencionó en el Capítulo III, en el Anexo H se exponen dos casos de estudio realizados previamente a la experimentación principal desarrollada en esta tesis.

En aquel apartado, se expone el impacto que esos casos de estudio tuvieron para definir la metodología final, pero en esta sección se contrastarán específicamente los Resultados de los casos de estudio contra los resultados actuales.

Experimento 1 vs Estudio Actual

En el Anexo H se describe detalladamente como se obtuvieron los resultados del Experimento 1, por lo cual, únicamente se utilizará gráficas de ejemplo para contrastar los resultados.

En la Figura 37, del lado izquierdo, se puede observar el Histograma de Atención de uno de los participantes del primer caso de estudio, mientras que, en el lado derecho, el Histograma de Atención de uno de los participantes del estudio actual.

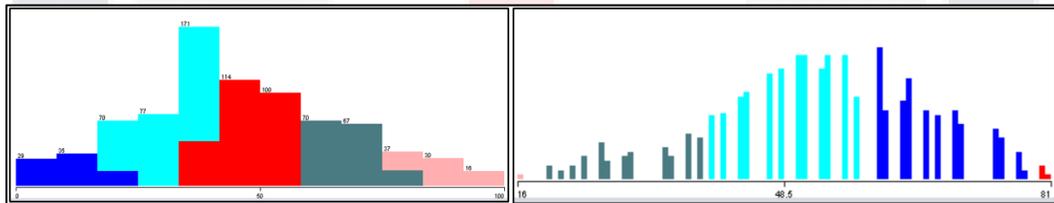


Figura 37 Comparación de Histogramas.

Fuera de los aspectos metodológicos, que ya se expusieron antes, específicamente en resultados hay bastantes diferencias:

- La adquisición jugó un papel fundamental, en específico el muestreo, puesto que, como se mencionó en el Capítulo III, para esta primera aproximación no se dominaba (ni se garantizó) una buena adquisición y procesamiento de las señales EEG; razón importante, además, el *software* de trabajo, *NeuroExperimenter*.

- TESIS TESIS TESIS TESIS TESIS
- Por lo anterior, el tamaño de los *datasets* es abismalmente distinto. Mientras que para el Experimento 1, el tamaño promedio de un *dataset* (el cual contiene 8 atributos más la clase) es de aproximadamente 300 instancias, para un *dataset* del estudio actual (con 18 atributos y la clase) ronda las 350,000 instancias.
 - En lo que respecta al número de participantes también fue muy distinto, aunque ninguno de los dos estadísticamente concluyente por la cantidad de participantes. El Experimento 1 del caso de estudio constó de 5 ciegos y 2 normovisuales, mientras que para el estudio actual fueron 10 normovisuales y 5 ciegos.
 - Falta de enfoque; en un primer momento, se pensaba abordar el problema mediante la identificación de algún patrón físico en las señales EEG, pero realmente sin un método ni herramienta específico (propio de la falta de conocimientos y revisión), no se obtuvo algo relevante.

Experimento 2 vs Estudio Actual

Dado que el Experimento 2 sirvió de base para el Estudio Actual, en este no hay realmente modificaciones en cuanto al registro o procesamiento de las señales. Donde sí existen diferencias significativas en el aspecto metodológico y de análisis de datos, en específico en el algoritmo implementado.

A continuación, se enlistan las diferencias de este Estudio con respecto a Actual:

- Grupo y cantidad de participantes (únicamente cuatro participantes normovisuales).
- Un solo video de divulgación científica, “¿Cómo funciona el cerebro?” y, por consiguiente, solo un cuestionario relativo a este video.
- Resolución del cuestionario por escrito.
- Sin videograbación de la sesión (No se había implementado para este momento).
- Uso de otra herramienta de análisis de datos, el algoritmo, *CfsSubEval* en *WEKA*.

Conclusiones.

Gracias al seguimiento de la metodología utilizada y a la aplicación de la Minería de Datos con los análisis realizados con *InfoGain* y los análisis visuales mediante las gráficas, se exponen las siguientes conclusiones a manera de respuesta de las preguntas de investigación planteadas.

6.1 Pregunta General:

¿Qué características relacionadas a la atención pueden encontrarse en los registros electroencefalográficos (EEG) al realizar una actividad enfocada al aprendizaje?

Atención a la pregunta:

Mediante la aplicación de la Minería de Datos a los registros electroencefalográficos se pueden encontrar ciertos patrones relacionados con la presencia o ausencia de ondas específicas en la atención cuando se realizan tareas de aprendizaje.

En este caso en específico, mediante la aplicación de *InfoGain* con *WEKA*, se encontró que, durante la observación de un video de divulgación científica y la resolución de un cuestionario relativo al video, las ondas más comúnmente asociadas a la atención son:

- *Delta*
- *Theta*
- *Low Alpha*

Además, con esta experimentación, y para estos participantes específicos, mediante un análisis gráfico y estadístico, se puede observar que el nivel de Atención promedio no va más allá del 60%.

Otro hallazgo importante mediante un análisis gráfico es el saber que para las ondas *High Beta* y *Low Beta*, las ondas más asociadas a la Atención, esta se presenta comúnmente en amplitudes bajas de estas ondas.

6.2 Preguntas específicas

- ¿Cuáles son las ondas cerebrales más asociadas a la atención?

Atención a la pregunta:

Como ya se mencionó en la Pregunta General, las tres ondas más presentes relacionadas a la atención en una tarea de aprendizaje son *Delta*, *Theta* y *Low Alpha* principalmente,

además de presencia de *High Alpha*, *Low Beta* y *High Beta* para algunos casos específicos (Consúltase “Aplicación de Ganancia de Información (*InfoGain*)” en el Capítulo VIII).

- ¿Qué algoritmos de *Machine Learning* pueden aplicarse a estos registros para una efectiva diferenciación?

Atención a la pregunta:

Hay bastantes métodos y algoritmos de *Machine Learning* que se pueden aplicar al momento de realizar un análisis de datos. Por ejemplo, en el Capítulo I, se abordan en la sección de Antecedentes, investigaciones que utilizaron Redes Neuronales Convolucionales, KNN, Máquinas de Soporte Vectorial y algunos clasificadores. Para este caso en concreto, se aplicó *Information Gain*, algoritmo utilizado en la construcción de árboles de decisión, puesto que permite conocer la “carga” de información o “impacto” que un atributo en específico tiene sobre la clase, “Nivel de Atención”. Para conocer cómo funciona a detalle este algoritmo, consúltase “Ganancia de Información (*Information Gain*)” en el Capítulo II.

- ¿Hay diferentes ondas cerebrales asociadas a la atención según sea el participante ciego o normovisual?

Atención a la pregunta:

También mediante la aplicación de *InfoGain*, se puede observar que, a diferencia de las personas con ceguera, seis de los participantes normovisuales tienen presencia de ondas *High Beta*, mientras que en el grupo contrario no se presenta en ninguno de los cinco.

- ¿Con qué actividades se pueden comparar los registros entre personas con ceguera y normovisuales en un enfoque de aprendizaje?

Atención a la pregunta:

Siguiendo la metodología del Dr. Lin, descrita en el Método de Investigación y las consideraciones sobre los videos educativos de Wang, se propusieron como actividades idóneas de aprendizaje, videos de divulgación científica aptos para todo público, disponibles en *Youtube*. Los videos tocan diversos temas científicos fáciles de asimilar y

muy didácticos, de la autoría del físico español Javier Santaolalla en su canal *Date un Voltio*.

6.3 Objetivo general

Identificar las principales características asociadas a la atención en usuarios con ceguera y normovisuales presentes en los registros electroencefalográficos mediante Minería de Datos durante la realización de actividades de aprendizaje y memoria.

Atención al objetivo:

Como se mencionó en la respuesta a la pregunta general de investigación, mediante un análisis de datos con el algoritmo *Information Gain*, se logró identificar que las ondas que más tienen impacto con el nivel de Atención en ambos grupos son:

- *Delta*
- *Theta*
- *Low Alpha*

Además de la presencia de *High Beta* en participantes normovisuales. Para una consulta más a detalle, revítese Resultados.

6.4 Objetivos específicos

- Revisar teoría y modelos de análisis de señales EGG relacionadas clasificación mediante algoritmos de *Machine Learning* (Minería de Datos)

Atención al objetivo:

En la sección Antecedentes, dentro del Capítulo I, pueden consultarse algunos de los trabajos más recientes que involucran el uso de *Machine Learning* y herramientas relacionadas aplicadas al análisis de registros EEG.

- Proponer actividades de aprendizaje que puedan ser fácilmente adaptables entre los diferentes tipos de usuarios y que a la postre, mediante ellas, se realizarán los registros EEG.

Atención al objetivo:

Con base en los artículos del Dr. Lin y el Dr. Wang, revisados en la sección “Metodologías base y apoyo” en el Capítulo III, Método de Investigación, se proponen como actividades de aprendizaje, videos de divulgación científica seguidos de un cuestionario relativo al mismo. Dado que son videos de divulgación aptos para todo público y disponibles de manera gratuita en el Canal de *YouTube* “*Date un Voltio*” del físico Javier Santaolalla, estos van dirigidos a un público no especializado en ciencias físicas, que pueden ser fácilmente adaptables mediante un audio para las personas con ceguera. Para más detalle, consúltese el Capítulo III.

- Construir las bases de datos de los registros para participantes ciegos y normovisuales de estudio y compararlas para identificar características de cada una.

Atención al objetivo:

Las bases de datos de la investigación constan de una serie de *datasets* generados a partir de *OpenViBE* y analizados con *WEKA* que pueden consultarse en el Capítulo Método de Investigación. Además. Si se desea conocer el contenido de un *dataset* como el utilizado en la investigación, consúltese el Anexo C.

- Implementar un algoritmo de *Machine Learning* (Minería de Datos) para el análisis e interpretación de los registros EEG.

Atención al objetivo:

Después de una revisión en la literatura, se optó por utilizar el *Information Gain* (*InfoGain*) en *WEKA*, debido a su capacidad para revelar el grado de “asociación” o de “mayor impacto” de un atributo sobre la clase, permitiendo así, identificar patrones con base a la relevancia que cada una de las señales (o potencias de las señales) tienen sobre el Nivel de Atención.

6.5 Comparación con los casos de estudio

Después de abordar las diferencias metodológicas y de resultados de los casos de estudio con respecto al Estudio Actual en los Capítulos III y las Discusiones respectivamente, se exponen las siguientes conclusiones:

- Si bien, los Experimentos 1 y 2 sirvieron principalmente para explorar el manejo de las herramientas de *Hardware* y *Software*, carecen de orden metodológico (principalmente el Experimento 1, la cual, además de un mal planteamiento, no cuenta tampoco con una adquisición y procesamiento de señales correcta).
- Ambos estudios, en conjunto con el Estudio Actual necesitan de muestras más grandes para cada grupo (normovisuales y ciegos) para ser totalmente contundentes. De manera breve, se estima que para que los resultados sean significativos, deberían aplicarse pruebas con un ambiente totalmente controlado en al menos 385 personas por grupo, es decir 770 participantes en total.
- Una metodología bien definida, basada en estudios previos, ayuda a determinar y encaminar mejor la experimentación y en general todo el proceso de investigación. En específico, los estudios presentados en los Antecedentes y en la revisión de las Metodologías Base, sirvieron para optar por un análisis de datos mediante algoritmos de Minería, en específico del *Information Gain* (En el Experimento 2 también se utilizó un algoritmo de Minería de Datos como el *CfsSubEval*, pero sin una metodología clara).

6.6 Aportaciones de la Investigación

Después de revisadas las preguntas y los objetivos de investigación, así como la comparación del Estudio Actual con los experimentos anteriores del Anexo H, a continuación, se muestran las aportaciones de la investigación:

1. Metodología de Investigación basada en la comparación de niveles de atención con la aplicación de algoritmos de Minería de Datos en personas ciegas (Capítulo III).
2. Caracterización de videos de divulgación científica como actividad de aprendizaje para tareas de medición de atención (Capítulo III).

3. Arquitectura de procesamiento y filtración de señales EEG en *OpenViBE* (Capítulo III).

6.7 Trabajo Futuro

Se contempla seguir trabajando con estudios que ayuden en la formación de métodos, herramientas y procesos para el análisis de aprendizaje, implementando nuevas tecnologías computacionales y electrónicas enfocadas en diferentes grupos, no solo personas con discapacidad.

De hecho, se ha comenzado a trabajar ya con un estudio para el análisis de señales cerebrales relacionadas al aprendizaje con personas con un Coeficiente Intelectual (CI) más alto, del cual se espera generar publicaciones futuras.

6.8 Productos generados

- Rodríguez, E. E., Rosales, A. G., Borja, K., German, M. O., & Álvarez, F. J. (2018). Proceso de medición de aprendizaje explícito (área lógica - matemática) aplicado en usuarios ciegos. In CONAIC (Ed.), *Avances sobre Reflexiones, Aplicaciones y Tecnologías*.
- Rodríguez, E. E., Morales, A. M., López, C., & Álvarez, F. J. (2019). Comparison of Levels of Attention between Blind and Normovisual People in a Learning Environment through EEG Analysis (Pendiente de Publicación). Paper presented at the II International Conference of Inclusive Technology and Education.
- Rodríguez, E. E. (2019). Análisis de Señales EEG para la Búsqueda de Patrones de Aprendizaje de Personas con Ceguera y Normovisuales. Paper presented at the Décimo Congreso Internacional La Investigación en el Posgrado, UAA., Aguascalientes, Aguascalientes, México.
- Rodríguez, E. E., Chery, J. S., Álvarez, T. d. J., & Álvarez, F. J. (2019). Hedonic Utility Scale (HED/UT) Modified as a User Experience Evaluation Method of Performing Talkback Tutorial for Blind People. In I. Global (Ed.), *User-Centered Software Development for the Blind and Visually Impaired: Emerging Research and Opportunities*.

Referencias.

- Aguiar, E., & Johnson, R. (2019). PowerPoint Presentation - 23 - Decision Trees 2.pdf. from <https://www3.nd.edu/~rjohns15/cse40647.sp14/www/content/lectures/23%20-%20Decision%20Trees%202.pdf>
- Alhussein, M., Muhammad, G., & Hossain, M. S. (2019). EEG Pathology Detection based on Deep Learning. *IEEE Access*.
- Alomari, R., Martin, M. V., MacDonald, S., Bellman, C., Liscano, R., & Maraj, A. (2017). *What your brain says about your password: Using brain-computer interfaces to predict password memorability*. Paper presented at the 2017 15th Annual Conference on Privacy, Security and Trust (PST).
- Aminoff, M. J. (2012). *Electrodiagnosis in clinical neurology*: Elsevier Health Sciences.
- Arango, J. E., Mazo, J. C., & Palacio, A. P. (2013). Sistema para rehabilitacion del síndrome del miembro fantasma utilizando interfaz cerebro-computador y realidad aumentada. *RISTI-Revista Ibérica de Sistemas e Tecnologías de Informação*(11), 93-106.
- Barrett, K. E. (2013). *Ganong fisiología médica (24a. ed.)*: McGraw Hill Mexico.
- Bird, J. J., Manso, L., Ribiero, E., Ekart, A., & Faria, D. (2018). *A study on mental state classification using EEG-based brain-machine interface*. Paper presented at the 9th International Conference on Intelligent Systems, IEEE.
- Braga, L. P. V., Valencia, L. I. O., & Carvajal, S. S. R. (2009). *Introducción a la Minería de Datos: E-PAPERS*.
- Cabezón, E. S. d. (2018). Las matemáticas nos hacen más libres y menos manipulables: BBVA Aprendemos Juntos.
- Ceri, S., Fraternali, P., Bongio, A., Brambilla, M., Comai, S., & Matera, M. (2003). *Morgan Kaufmann series in data management systems: Designing data-intensive Web applications*: Morgan Kaufmann.
- Chai, M. T., Saad, M. N. M., Kamel, N., & Malik, A. S. (2017, 13-15 Dec. 2017). *EEG analysis of color effects using effective connectivity based on graph theory during a multimedia learning task*. Paper presented at the 2017 IEEE Life Sciences Conference (LSC).
- Chen, C. M., Wang, J. Y., & Yu, C. M. (2017). Assessing the attention levels of students by using a novel attention aware system based on brainwave signals. *British Journal of Educational Technology*, 48(2), 348-369.
- Cuéllar, L. D. (2018). Presentación: Introducción a Algoritmos Clasificadores.
- Du, J., Xu, R., & Wen, Z. (2017, 15-17 Dec. 2017). *A symbolic representation approach of EEG signals for emotion recognition*. Paper presented at the 2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC).
- Eduardo, M. (2019a). Aprendizaje por Refuerzo - refuerzo.pdf.
- Eduardo, M. (2019b). Aprendizaje Semisupervisado - semisupervisado.pdf.
- Farnham-Diggory, S. (1983). *Dificultades de aprendizaje*: Morata.
- Fox, S. I. (2014). *Fisiología humana (13a. ed.)*: McGraw Hill Mexico.
- Francois, P. J. (2016, 06/16/19). What Is Machine Learning? https://www.ibm.com/developerworks/community/blogs/jfp/entry/What_Is_Machine_Learning?ang=en
- García, T. T. (2011). Manual básico para enfermeros en electroencefalografía. *Enfermería Docente*, 29-33.
- González, A. (2019). Conceptos básicos de Machine Learning. from <https://cleverdata.io/conceptos-basicos-machine-learning/>
- Hall, J. E. (2017). *Guyton E Hall Tratado De Fisiología Médica*: Elsevier Brasil.
- Hu, B., Li, X., Sun, S., & Ratcliffe, M. (2016). Attention recognition in EEG-based affective learning research using CFS+ KNN algorithm. *IEEE/ACM transactions on computational biology and bioinformatics*, 15(1), 38-45.
- INEGI. (2019). Discapacidad. Retrieved 03/11, 2019, from <https://www.inegi.org.mx/temas/discapacidad/>

- Jasper, H. H. (1958). The ten-twenty electrode system of the International Federation. *Electroencephalogr. Clin. Neurophysiol.*, 10, 370-375.
- Kaspersky. (2019). ¿Qué es la minería de datos? , from <https://latam.kaspersky.com/resource-center/definitions/data-mining>
- Kimmatkar, N. V., & Babu, B. V. (2017, 11-12 May 2017). *Initial analysis of brain EEG signal for mental state detection of human being*. Paper presented at the 2017 International Conference on Trends in Electronics and Informatics (ICEI).
- Kober, S. E., Wood, G., Kampl, C., Neuper, C., & Ischebeck, A. (2014). Electrophysiological correlates of mental navigation in blind and sighted people. *Behavioural brain research*, 273, 106-115.
- Kriegseis, A., Hennighausen, E., Rösler, F., & Röder, B. (2006). Reduced EEG alpha activity over parieto-occipital brain areas in congenitally blind adults. *Clinical neurophysiology*, 117(7), 1560-1573.
- Lancheros-Cuesta, D. J., Arias, J. L. R., Forero, Y. Y., & Duran, A. C. (2018). *Evaluation of e-learning activities with NeuroSky MindWave EEG*. Paper presented at the 2018 13th Iberian Conference on Information Systems and Technologies (CISTI).
- Lin, F.-R., & Kao, C.-M. (2018). Mental effort detection using EEG data in E-learning contexts. *Computers & Education*, 122, 63-79.
- Loonis, R. F., Brincat, S. L., Antzoulatos, E. G., & Miller, E. K. (2017). A meta-analysis suggests different neural correlates for implicit and explicit learning. *Neuron*, 96(2), 521-534. e527.
- López, C. P. (2007). *Minería de datos: técnicas y herramientas*: Paraninfo Cengage Learning.
- Mehmood, R. M., Du, R., & Lee, H. J. (2017). Optimal feature selection and deep learning ensembles method for emotion recognition from human brain EEG sensors. *IEEE Access*, 5, 14797-14806.
- Mellender, F. (2018). NeuroExperimenter. from <https://sites.google.com/site/fredm/neuroexperimenter>
- Miraglia, F., Vecchio, F., & Rossini, P. M. (2018). Brain electroencephalographic segregation as a biomarker of learning. *Neural Networks*, 106, 168-174.
- NeuroSky. (2015a). Effective Learner. Retrieved 08/25, 2018, from <https://store.neurosky.com/products/effective-learner>
- NeuroSky. (2015b). NeuroSky Store. Retrieved 08/25, 2018, from <https://store.neurosky.com/>
- NeuroSky. (2015c). NeuroWikium. Retrieved 08/25, 2018, from <https://store.neurosky.com/products/neurowikium>, from <https://wikium.ru/>
- OMS. (2017). Ceguera y discapacidad visual. Retrieved 09/06, 2018, from <http://www.who.int/es/news-room/fact-sheets/detail/blindness-and-visual-impairment>
- ONCE. (2018). Concepto de ceguera y deficiencia visual. Retrieved 12/03/2018, 2018, from <https://www.once.es/dejanos-ayudarte/la-discapacidad-visual/concepto-de-ceguera-y-deficiencia-visual?searchterm=ceguera>
- RadioBL. (2019). Normalistas aprenden lengua de señas y Braille - BI Noticias Aguascalientes. *BINoticias.com*.
- RL. (2017, 08/15/2017). Diseñan silla de ruedas que se controla con la mente. *Milenio*. Retrieved from <http://www.milenio.com/estilo/disenan-silla-de-ruedas-que-se-controla-con-la-mente>
- Romero, V. M. A., & Díaz, E. G. (2001). *Texto de neurociencias cognitivas: El Manual Moderno*.
- Roy, S., Kiral-Kornek, I., & Harrer, S. (2018). *Deep Learning Enabled Automatic Abnormal EEG Identification*. Paper presented at the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC).
- Rueda Cebollero, G. (2012). Procesado de señales electroencefalográficas para determinar características espectrales de episodios epilépticos.
- Sadock, B., & Ruiz, P. (2015). *Kaplan & Sadock's synopsis of psychiatry: behavioral sciences*: Walters Kluwer.
- SCCN. (2018). What is EEGLAB? Retrieved 08/25, 2018, from <https://sccn.ucsd.edu/eeglab/index.php>
- Subhani, A. R., Mumtaz, W., Saad, M. N. B. M., Kamel, N., & Malik, A. S. (2017). Machine learning framework for the detection of mental stress at multiple levels. *IEEE Access*, 5, 13545-13556.
- Tan, P. N. (2018). *Introduction to Data Mining*: Pearson.
- Tech., M. (2019). Discover OpenViBE | OpenViBE. Retrieved 06/14/19, 2019, from <http://openvibe.inria.fr/discover/>
- Torres, F., Sánchez, C., & Baus, K. P. (2014). Adquisición y análisis de señales cerebrales utilizando el dispositivo MindWave. *Maskana*, 83-93.

- Wang, S., Guo, B., Zhang, C., Bai, X., & Wang, Z. (2017, 14-16 Oct. 2017). *EEG detection and de-noising based on convolution neural network and Hilbert-Huang transform*. Paper presented at the 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI).
- Wang, W.-F., Chen, C.-M., & Wu, C.-H. (2015). *Effects of different video lecture types on sustained attention, emotion, cognitive load, and learning performance*. Paper presented at the 2015 IIAI 4th International Congress on Advanced Applied Informatics.
- WEKA. (2019). Weka 3 - Data Mining with Open Source Machine Learning Software in Java. from <https://www.cs.waikato.ac.nz/ml/weka/>
- Wen, Z., Xu, R., & Du, J. (2017, 15-17 Dec. 2017). *A novel convolutional neural networks for emotion recognition based on EEG signal*. Paper presented at the 2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC).





UNIVERSIDAD AUTÓNOMA
DE AGUASCALIENTES

Anexos

Anexo A: Cuestionarios sobre los videos y links de acceso.	1
Anexo B. Carta de Consentimiento para participación en la experimentación.	5
Anexo C. Contenido de un <i>dataset</i> de EEG.	6
Anexo D. Histogramas y Tablas de datos los participantes ciegos y normovisuales.	7
4.1 Participantes ciegos (3 – 5).	7
4.2 Participantes normovisuales (3 – 10).	9
Anexo E. Gráficas de atención.	13
5.1 Participantes ciegos.	13
5.2 Participantes normovisuales.	15
Anexo F. Relación del Nivel de Atención con los niveles Low Beta y High Beta de cada participante. 20	
6.1 Participantes ciegos.	20
6.2 Participantes normovisuales.	23
Anexo G. <i>OpenViBE</i> y <i>WEKA</i>	31
7.1 <i>OpenViBE</i>	31
7.2 <i>WEKA</i> (Waikato Environment for Knowledge Analysis)	34
Anexo H. Casos de Estudio	35
8.1 Experimento: Aprendizaje Explícito e Implícito.	35
8.2 Experimento 2: Análisis mediante Selección de atributos con CfsSubEval de <i>WEKA</i>	47
Anexo I. Publicación en CONTIE 2018.	50
Anexo J. Publicación pendiente en CONTIE 2019.	52
Anexo K. Cartel publicado en CIIP UAA 2019.	54
Anexo L. Capítulo en libro <i>User-Centered Software Development for the Blind and Visually Impaired: Emerging Research and Opportunities</i>	56

Anexo A: Cuestionarios sobre los videos y links de acceso.

“¿Cómo funciona el cerebro?”

Conteste de manera breve las siguientes preguntas. No hay inconvenientes por preguntas correctas o incorrectas:

- 1.- ¿Qué es la Neurociencia?
- 2.- ¿Al estudiar matemáticas, el cerebro activa?
 - a) La zona de la corteza prefrontal
 - b) La Amígdala
 - c) La hipófisis
- 3.- ¿Cuál es la unidad de procesamiento del cerebro?
 - a) El Axón
 - b) La Dendrita
 - c) La Neurona
 - d) El Núcleo
- 4.- ¿Cómo se crean y envían las señales eléctricas de las neuronas?
- 5.- ¿Qué es una sinapsis?

Link de Acceso al video:

<https://www.youtube.com/watch?v=Svp0DohnpNA>

“La Tierra no gira en círculos alrededor del Sol”

Conteste de manera breve las siguientes preguntas. No hay inconvenientes por preguntas correctas o incorrectas:

- 1.- ¿Para qué servía el éter decimonónico?
- 2.- Si el sujeto 1 está parado y ve pasar al sujeto 2, ¿Cuál de los sujetos está en movimiento?

- a) El sujeto 2 porque es el que va pasando.
 - b) El sujeto 1.
 - c) Ambos y ninguno a la vez. Depende de quién lo diga, si el sujeto 1 o el sujeto 2.
- 3.- ¿Qué tipo de movimiento realiza el sistema solar?
- 4.- ¿Alrededor de qué centro se mueve el sol?
- a) Centro del Universo
 - b) Centro de la galaxia (vía láctea)
 - c) Centro del cinturón de Orión
- 5.- ¿Quiénes fueron los físicos que descubrieron que el éter no era una referencia universal del movimiento y en qué año lo hicieron?
- a) Einstein y Hawkin 1896.
 - b) Michelson y Morley, 1887.
 - c) Morley y Faraday, 1886.

Link de Acceso al video:

https://www.youtube.com/watch?v=XniO_bTYIYY

“¿Cómo surgió la vida en la Tierra?”

Conteste de manera breve las siguientes preguntas. No hay inconvenientes por preguntas correctas o incorrectas:

- 1.- ¿Qué es la imagen especular?
- 2.- ¿Cómo se llaman las moléculas que dan lugar a la vida?
 - a) Moléculas orgánicas.
 - b) Moléculas inorgánicas.
 - c) Moléculas organometálicas.
- 3.- De los siguientes enunciados, ¿cuál es la Ley Fundamental en Física?
 - a) Todo lo que no está prohibido, no existe.
 - b) Todo lo que no está prohibido, no tiene que pasar.
 - c) Todo lo que no está prohibido, es obligatorio.

4.- ¿En qué siglo se descubrió la fuerza nuclear débil?

5.- ¿Cómo actúa la fuerza nuclear débil?

a) Actúa de forma asimétrica. Puede distinguir entre izquierda y derecha.

b) Actúa de forma aritmética. Puede dividir los componentes de nuestro cuerpo.

c) Actúa de forma simétrica. Es por ello que el cuerpo humano de manera exterior es simétrico.

Link de Acceso al video:

<https://www.youtube.com/watch?v=A209PQLztGg>

“5 cosas que tal vez no sabías sobre nuestro Universo”

Conteste de manera breve las siguientes preguntas. No hay inconvenientes por preguntas correctas o incorrectas:

1.- ¿Cómo se llama la estrella más cercana al Sol?

2.- ¿Cuáles son los problemas que resuelve la Teoría de la Inflación?

a) Problema del Horizonte (misma temperatura en todo el universo), de la planitud (que el universo sea exactamente plano) y sobre las arrugas del fondo cósmico del microondas.

b) Problemas que surgieron de la Teoría del Principio Cosmológico.

c) Qué tan grande es el universo.

3.- ¿Qué tan grande es el universo?

a) Diez veces el tamaño de la galaxia.

b) Infinito o finito sin bordes.

c) Finito con bordes.

4.- ¿De qué trata el principio cosmológico?

5.- ¿De qué depende la curvatura del universo?

a) De la cantidad de Materia y Energía que contiene el universo.

b) De la cantidad de bordes que tenga.

c) De la cantidad de energía y bordes que tenga.

Link de Acceso al video:

<https://www.youtube.com/watch?v=iOfovFgHHbw>

“¿Qué pasaría si se invirtiera el Campo Magnético de la Tierra?”

Conteste de manera breve las siguientes preguntas. No hay inconvenientes por preguntas correctas o incorrectas:

- 1.- ¿Qué es el electromagnetismo?
- 2.- ¿De qué está formado principalmente el núcleo de la Tierra?
 - a) Níquel y Oro.
 - b) Níquel y Uranio.
 - c) Níquel y Hierro.
- ¿Qué tipos de corrientes produce la diferencia de temperatura con la profundidad que tiene la Tierra?
 - a) Corrientes geotérmicas.
 - b) Corrientes geomagnéticas.
 - c) Corrientes de convección.
- 4.- ¿Cuál de los siguientes enunciados es un efecto importante de la magnetosfera?
 - a) Proteger a la Tierra junto con la atmósfera del viento solar.
 - b) Producir auroras boreales.
 - c) Proteger a la Tierra de la erosión.
- 5.- ¿Qué es más peligroso: la inversión del campo magnético o el debilitamiento permanente de este?
- 6.- ¿Cómo se puede conocer la historia del campo magnético?
 - a) Estudiando las capas de la Tierra y sedimentos oceánicos.
 - b) Estudiando el núcleo de la Tierra.
 - c) Estudiando la migración de los animales.

Link de Acceso al video:

<https://www.youtube.com/watch?v=uhRfyCdGC7c>

Anexo B. Carta de Consentimiento para participación en la experimentación.



CARTA DE CONSENTIMIENTO INFORMADO PARA PARTICIPACIÓN EN EXPERIMENTACIÓN.

Yo, _____, de _____ años, acepto voluntariamente participar en el proceso de experimentación del proyecto de tesis titulado “ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUEDA DE PATRONES DE APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES”.

Comprendo que la experimentación consiste en:

- Observar un video educativo con una duración aproximada de 6 min.
- Resolución de un breve cuestionario de cinco preguntas relacionadas con el video.
- Registro de las ondas electroencefalográficas durante la observación del video y la solución del cuestionario.
- Videograbación de la experimentación.

Instrucciones de la experimentación:

- Sentado en una postura cómoda y preferentemente relajado, se colocará la diadema MindWave al participante y audifonos alámbricos, se configurarán los aspectos técnicos.

El participante elegirá entre 5 videos educativos, el tema que le parezca mas interesante.

El participante mantendrá cerrado los ojos durante los primeros 30s, de adquisición; tiempo que empezará a correr cuando se le indique.

- El participante observará de manera atenta el video de su elección.
- Finalizado el video, el participante procederá a resolver de manera verbal un cuestionario de cinco preguntas relativas al video anterior con una duración máxima de 6 minutos.
- Durante el video y el cuestionario se videograbará la experimentación para su análisis con fines académicos.

Autorizo que mis datos, registros cerebrales y cuestionario sean utilizados solo con fines científicos y académicos, pertinentes a la presente experimentación, y comprendo que toda la información aquí generada, será tratada con la privacidad y confidencialidad merecida a mi persona.

Atentamente

Fecha: / /

Figura 38 Carta de Consentimiento Informado de la Experimentación.

Anexo C. Contenido de un *dataset* de EEG.

En el presente Anexo se exponen las partes que componen a un data set genérico obtenido mediante *OpenViBE* y guardado en formato .csv.

Un archivo .csv puede ser manipulado con diversos programas; en este caso, por cuestión de simplicidad, se utilizó Microsoft Excel (en su última versión hasta el momento, 2019).

Partes del *Dataset*:

En la Figura 39 se muestran encuadrados y enumeradas las distintas partes del Data Set que a continuación se describen:

2	Time:512Hz	Epoch	Electrode	Attention	Meditation	Delta	Theta	Low Alpha	High Alpha	Low Beta	High Beta	Low Gamma	Mid Gamma	Delta Signal	Theta Signal	Alpha Signal	Beta Signal	Gamma Signal	Nivel de Atención
3	0.00195313	24	63	37	77374	4506	919	1349	854	938	198	112	3.39E-06	1.06E-05	1.06E-05	0.000757007	0.532777122	buena	
4	0.00390625	43	63	37	77374	4506	919	1349	854	938	198	112	3.23E-05	9.99E-05	9.95E-05	0.006861058	3.268128137	buena	
5	0.00585938	54	63	37	77374	4506	919	1349	854	938	198	112	0.000155523	0.000478323	0.000473761	0.031072864	8.625185445	buena	
6	0.0078125	65	63	37	77374	4506	919	1349	854	938	198	112	0.000515977	0.001574664	0.001548063	0.095576155	12.27328914	buena	
7	0.00976563	72	63	37	77374	4506	919	1349	854	938	198	112	0.001347292	0.004074411	0.003967645	0.228057025	8.307138179	buena	
8	0.01171875	88	63	37	77374	4506	919	1349	854	938	198	112	0.002982814	0.008927657	0.008929203	0.454745975	-2.941163756	buena	
9	0.01367188	114	63	37	77374	4506	919	1349	854	938	198	112	0.005864488	0.01735186	0.016466301	0.793795938	-13.56683223	buena	
10	0.015625	132	63	37	77374	4506	919	1349	854	938	198	112	0.010557755	0.030848769	0.028799436	1.250994212	-15.67160706	buena	
11	0.01757813	154	63	37	77374	4506	919	1349	854	938	198	112	0.017768909	0.05122324	0.049938764	1.817876873	-9.624762101	buena	
12	0.01953125	125	63	37	77374	4506	919	1349	854	938	198	112	0.028351944	0.080563266	0.072300384	2.468194078	-4.06512655	buena	
13	0.02148438	106	63	37	77374	4506	919	1349	854	938	198	112	0.043295363	0.121152981	0.106229822	3.153092402	-6.825751781	buena	
14	0.0234375	85	63	37	77374	4506	919	1349	854	938	198	112	0.063688953	0.175322133	0.149801413	3.796344103	-16.57226533	buena	
15	0.02539063	80	63	37	77374	4506	919	1349	854	938	198	112	0.090679018	0.245262836	0.203594361	4.293708401	-23.92926412	buena	
16	0.02734375	86	63	37	77374	4506	919	1349	854	938	198	112	0.125427941	0.332867015	0.267506891	4.520091147	-19.52271375	buena	
17	0.02929688	106	63	37	77374	4506	919	1349	854	938	198	112	0.169092495	0.439631347	0.340666171	4.349584357	-1.323587595	buena	
18	0.03125	119	63	37	77374	4506	919	1349	854	938	198	112	0.22823477	0.566637087	0.421413176	3.674575706	23.40583341	buena	
19	0.03320313	105	63	37	77374	4506	919	1349	854	938	198	112	0.287774729	0.714565543	0.507416237	2.434056243	41.98853664	buena	
20	0.03515625	80	63	37	77374	4506	919	1349	854	938	198	112	0.36510059	0.883682522	0.595687716	6.625447343	43.41801364	buena	
21	0.03710938	64	63	37	77374	4506	919	1349	854	938	198	112	0.45593003	1.07375643	0.682622416	-1.692870504	25.96157419	buena	
22	0.0390625	71	63	37	77374	4506	919	1349	854	938	198	112	0.561329515	1.283951018	0.764004831	-4.407506072	0.882394713	buena	
23	0.04101563	91	63	37	77374	4506	919	1349	854	938	198	112	0.68227887	1.512770951	0.835094761	-7.357076605	-14.04834264	buena	
24	0.04296875	105	63	37	77374	4506	919	1349	854	938	198	112	0.819672374	1.758097608	0.896821694	-10.3379979	-9.414533246	buena	
25	0.04492188	86	63	37	77374	4506	919	1349	854	938	198	112	0.974334558	2.017279948	0.926045438	-13.1129341	6.338467981	buena	
26	0.046875	75	63	37	77374	4506	919	1349	854	938	198	112	1.147027926	2.287200179	0.93380033	-15.42787984	14.10077614	buena	
27	0.04882813	63	63	37	77374	4506	919	1349	854	938	198	112	1.338439381	2.564291685	0.915473697	-17.03727862	6.23811928	buena	
28	0.05078125	63	63	37	77374	4506	919	1349	854	938	198	112	1.549154426	2.844507994	0.860943559	-17.73292663	-19.79919108	buena	
29	0.05273438	69	63	37	77374	4506	919	1349	854	938	198	112	1.779638074	3.123334457	0.768732388	-17.36652385	-33.38861936	buena	
30	0.0546875	75	63	37	77374	4506	919	1349	854	938	198	112	2.030230424	3.395848914	0.636196513	-15.86369693	-26.91627084	buena	
31	0.05664063	82	63	37	77374	4506	919	1349	854	938	198	112	2.301152562	3.656819804	0.461729303	-13.22979168	-7.718529506	buena	

Figura 39 *Dataset* de ejemplo.

1. Nombre del *Dataset*.
2. Columnas: Atributos del *Dataset*.
3. Atributo de Tiempo, con una Frecuencia de Muestreo = 512Hz (Se toma una muestra cada 1.95313×10^{-3} segundos).
4. EEG Crudo.
5. Atributos Atención y Meditación.
6. Atributos Potencias de las ondas (Delta, Theta, Alfa Baja, Alfa Alta, Beta Baja, Beta Alta, Gamma Baja, Gamma Media).

7. Atributos Ondas (Señales: Delta, Theta, Alpha, Beta, Gamma). Añadidas a partir de Excel, obtenidas también con *OpenViBE*.
8. Atributo Nivel de Atención (Es el único que no se obtiene desde *OpenViBE*, este se genera a partir de una clasificación mediante una fórmula de condicionales sencillos del atributo “Attention”, dividiendo en cinco partes iguales de 0 – 100, los niveles de este atributo).

Este, como todos los demás *Datasets*, son analizados posteriormente en el Explorador de *WEKA*.

Anexo D. Histogramas y Tablas de datos los participantes ciegos y normovisuales.

4.1 Participantes ciegos (3 – 5).

Participante 3.

Tabla 13 Datos del participante ciego 3.

Edad	28
Sexo	Mujer
Elección de video	<i>¿Cómo funciona el Cerebro?</i>
Preguntas correctas	1
Atención promedio	47.617

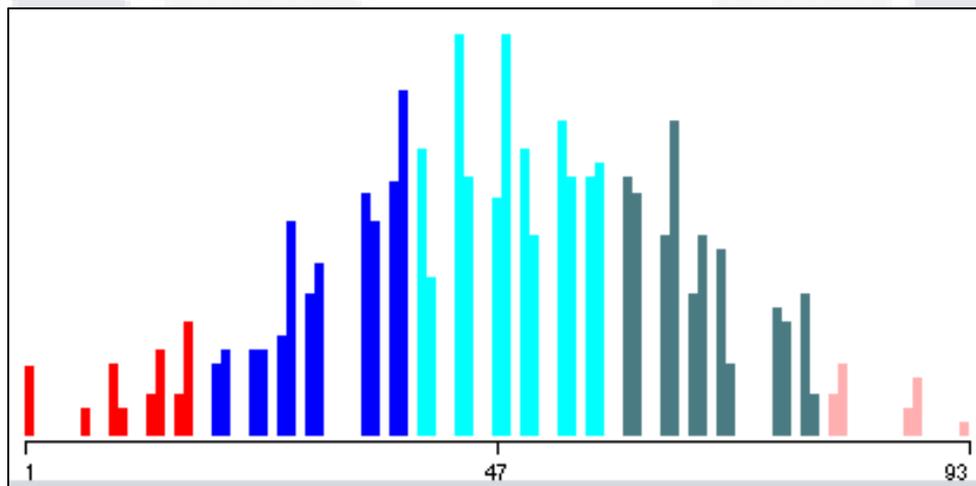


Figura 40 Histograma de Atención del participante ciego 3.

Participante 4.

Tabla 14 Datos del participante ciego 4.

Edad	42
Sexo	Hombre
Elección de video	<i>¿Cómo funciona el Cerebro?</i>
Preguntas correctas	3
Atención promedio	55.316

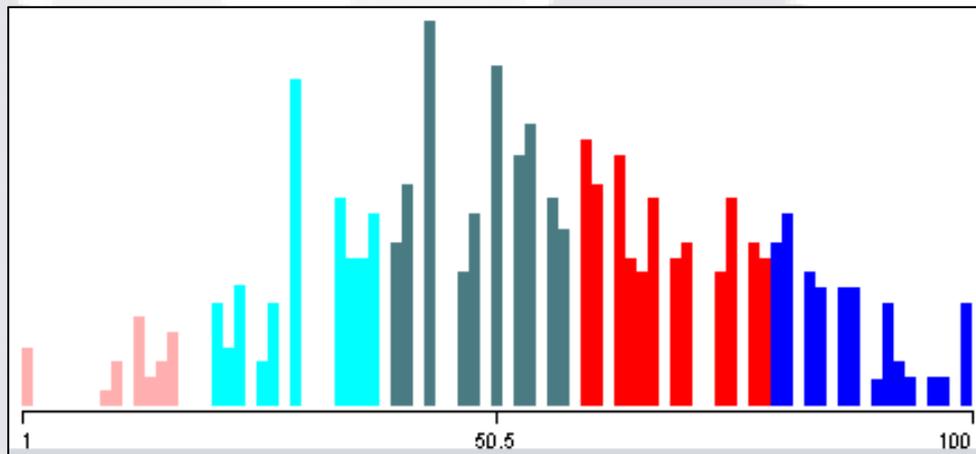


Figura 41 Histograma de Atención del participante ciego 4.

Participante 5.

Tabla 15 Datos del participante ciego 5.

Edad	41
Sexo	Hombre
Elección de video	<i>5 cosas que tal vez no sabias sobre nuestro universo</i>
Preguntas correctas	2
Atención promedio	58.71

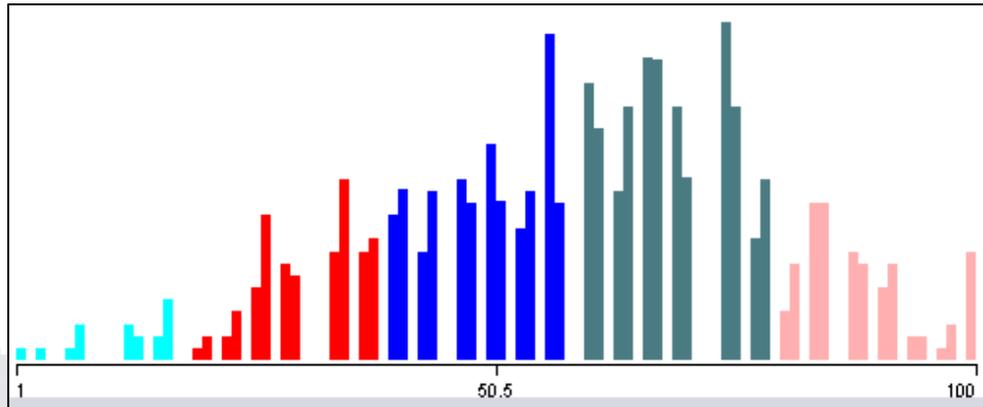


Figura 42 Histograma de Atención del Participante ciego 5.

4.2 Participantes normovisuales (3 – 10).

Participante 3.

Tabla 16 Datos del participante normovisual 3.

Edad	21
Sexo	Hombre
Elección de video	<i>¿Qué pasaría si se invirtiera el campo magnético?</i>
Preguntas correctas	4
Atención promedio	56.45

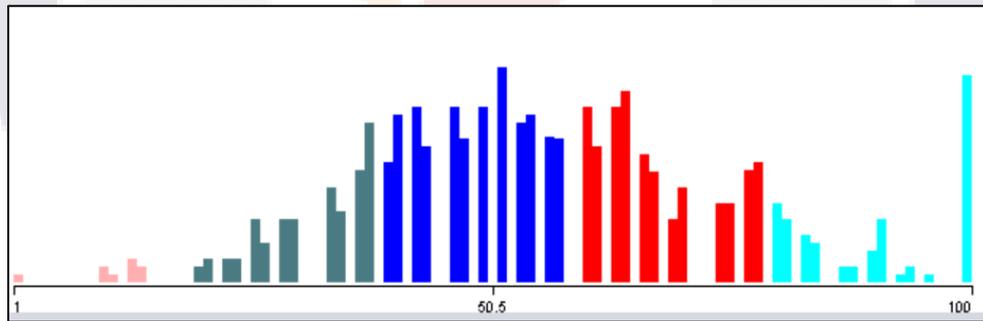


Figura 43 Histograma de Atención del participante normovisual 3.

Participante 4.

Tabla 17 Datos del participante normovisual 4.

Edad	24
Sexo	Hombre
Elección de video	<i>La tierra no gira en círculos alrededor del sol</i>
Preguntas correctas	3
Atención promedio	51.29

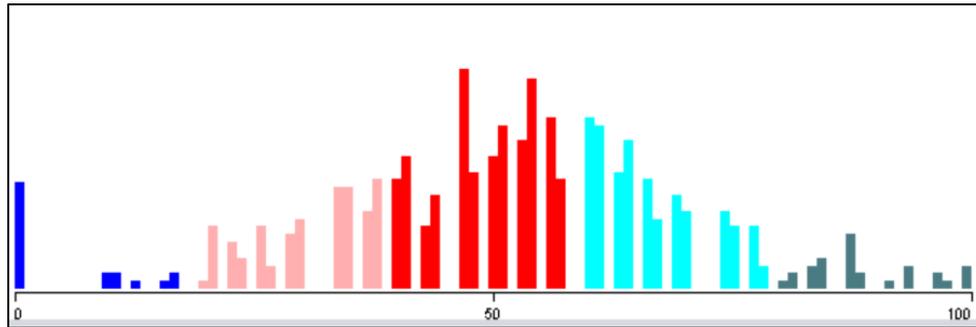


Figura 44 Histograma de Atención del participante normovisual 4.

Participante 5.

Tabla 18 Datos del participante normovisual 5.

Edad	29
Sexo	Hombre
Elección de video	<i>¿Cómo funciona el cerebro?</i>
Preguntas correctas	5
Atención promedio	59.15

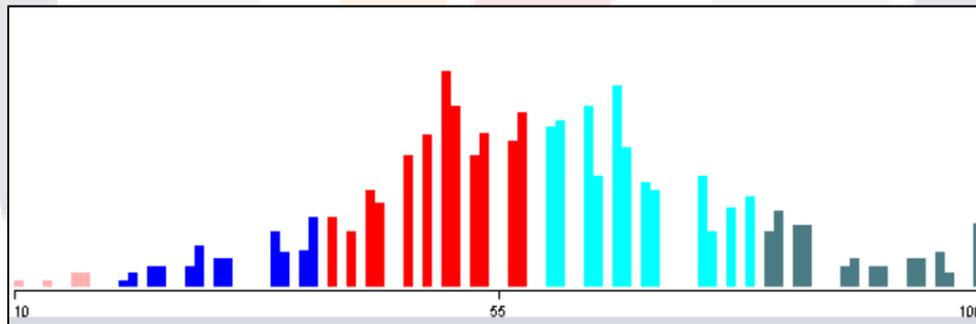


Figura 45 Histograma de Atención del participante normovisual 5.

Participante 6.

Tabla 19 Datos del participante normovisual 6.

Edad	30
Sexo	Mujer
Elección de video	<i>¿Cómo funciona el cerebro?</i>
Preguntas correctas	4
Atención promedio	45.306

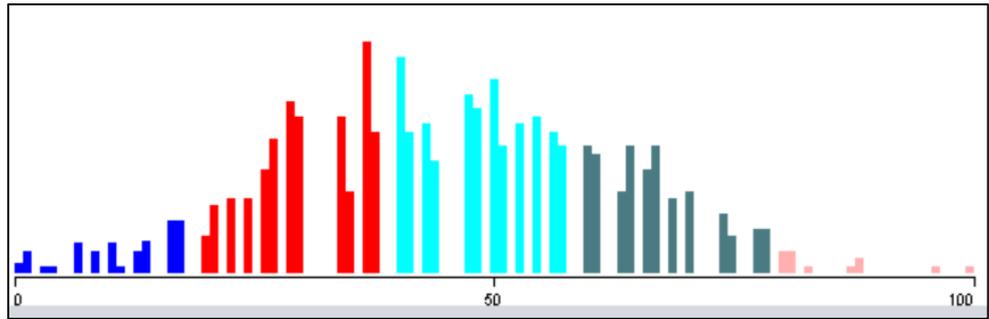


Figura 46 Histograma de Atención del participante normovisual 6.

Participante 7.

Tabla 20 Datos del participante normovisual 7.

Edad	21
Sexo	Hombre
Elección de video	<i>5 cosas que no sabias de nuestro universo</i>
Preguntas correctas	2
Atención promedio	61.742

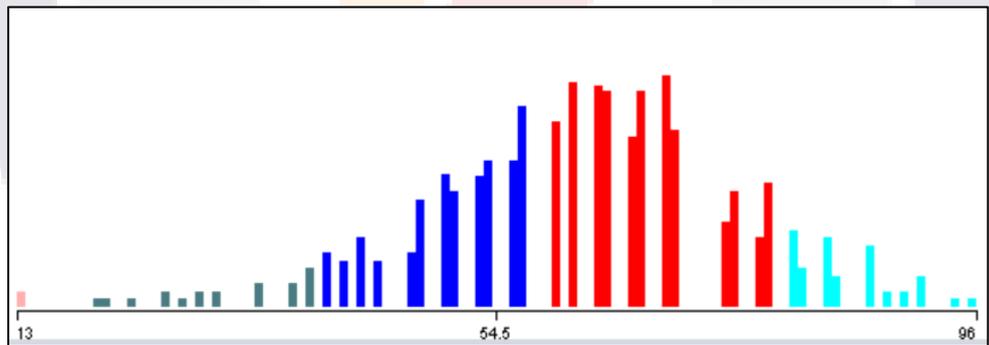


Figura 47 Histograma de Atención del participante normovisual 7.

Participante 8.

Tabla 21 Datos del participante normovisual 8.

Edad	31
Sexo	Hombre
Elección de video	<i>¿Qué pasaría si se invirtiera el campo magnético?</i>
Preguntas correctas	4
Atención promedio	56.36

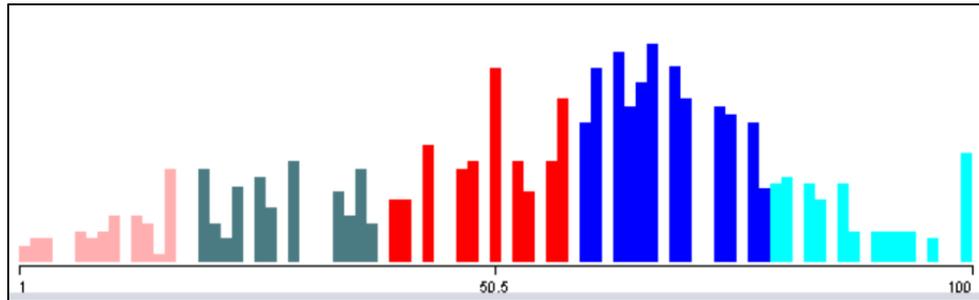


Figura 48 Histograma de Atención del participante normovisual 8.

Participante 9.

Tabla 22 Datos del participante normovisual 9.

Edad	22
Sexo	Mujer
Elección de video	<i>5 cosas que tal vez no sabias de nuestro universo</i>
Preguntas correctas	3
Atención promedio	50.9

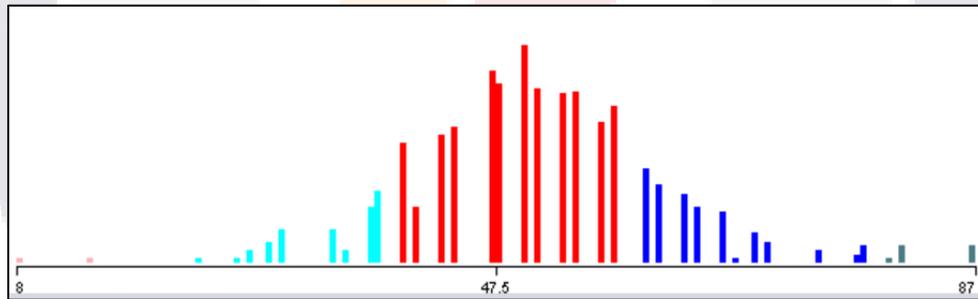


Figura 49 Histograma de Atención del participante normovisual 9.

Participante 10.

Tabla 23 Datos del participante normovisual 10.

Edad	37
Sexo	Mujer
Elección de video	<i>¿Cómo funciona el cerebro?</i>
Preguntas correctas	2
Atención promedio	38.266

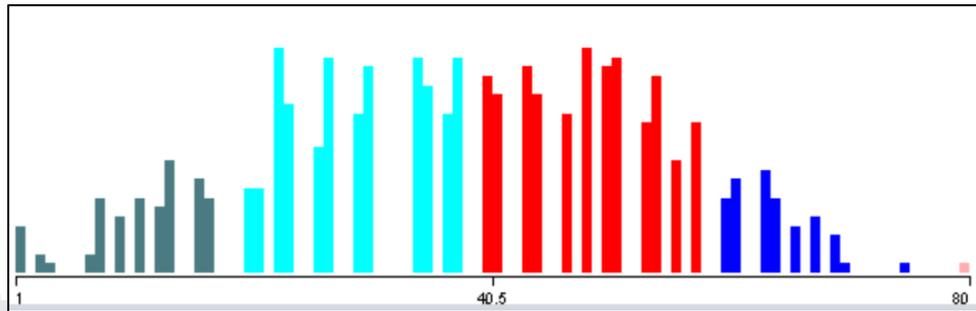


Figura 50 Histograma de Atención del participante normovisual 10.

Anexo E. Gráficas de atención.

A continuación, se presentan las gráficas de atención (atributo “*Attention*”) de los participantes ciegos y normovisuales restantes que no se mostraron en el Capítulo VIII Resultados.

5.1 Participantes ciegos.

Participante 3.

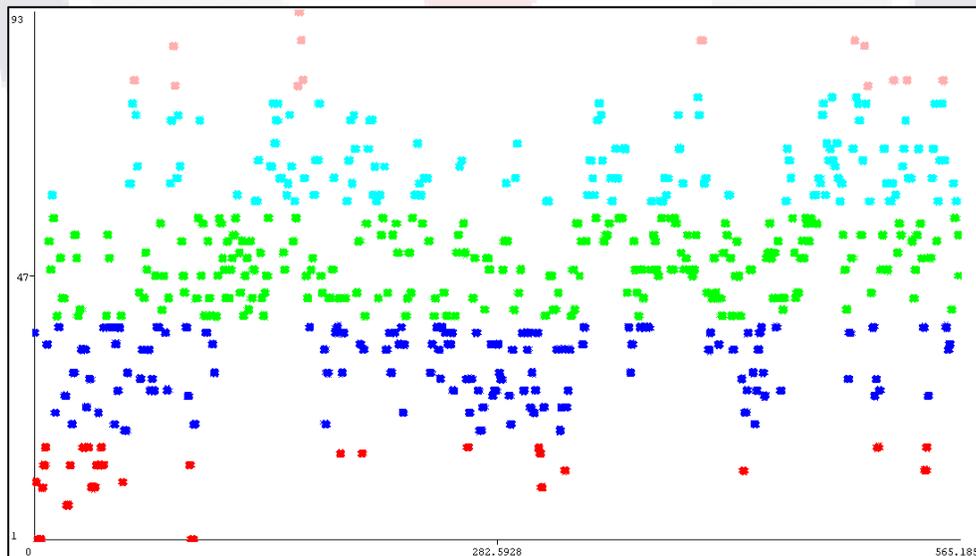


Figura 51 Gráfica de atención del participante ciego 3

Muy similar al participante 2, en este registro, la mayor parte del tiempo, el participante rondo entre niveles “Malo”, “Regular” y “Bueno”, teniendo un nivel de atención medio de 47.617, con niveles “Muy Buena” casi ausentes y un poco más de “Muy Mala”.

Participante 4.

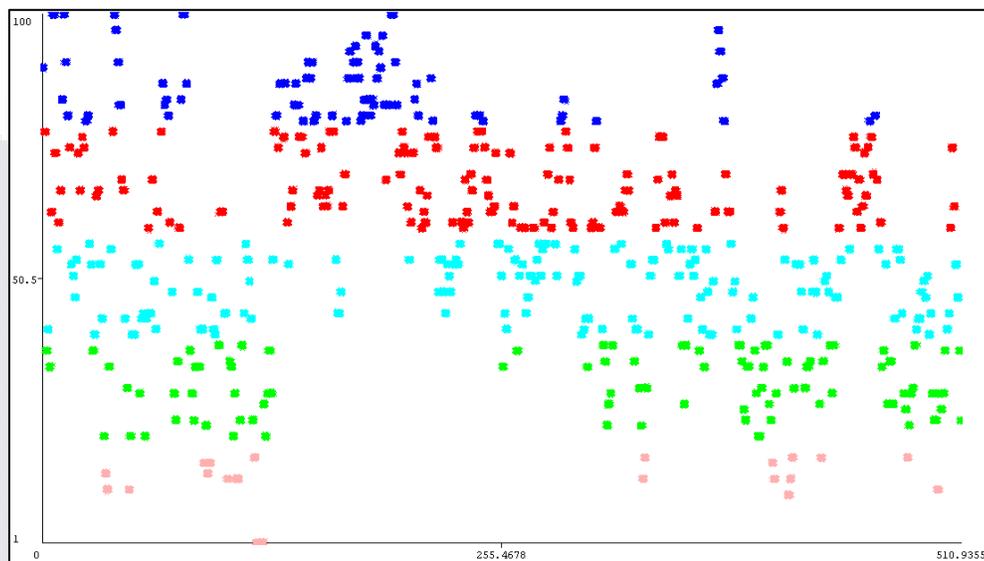


Figura 52 Gráfica de atención del participante ciego 4.

Este participante obtuvo un nivel de atención promedio de 55.316, un poco por encima de 50. Pasando el primer cuarto y hasta aun poco más de la mitad, no hubo presencia de niveles bajos, (“Mala” y “Muy Mala”), sin embargo, progresivamente fue cayendo.

Participante 5.

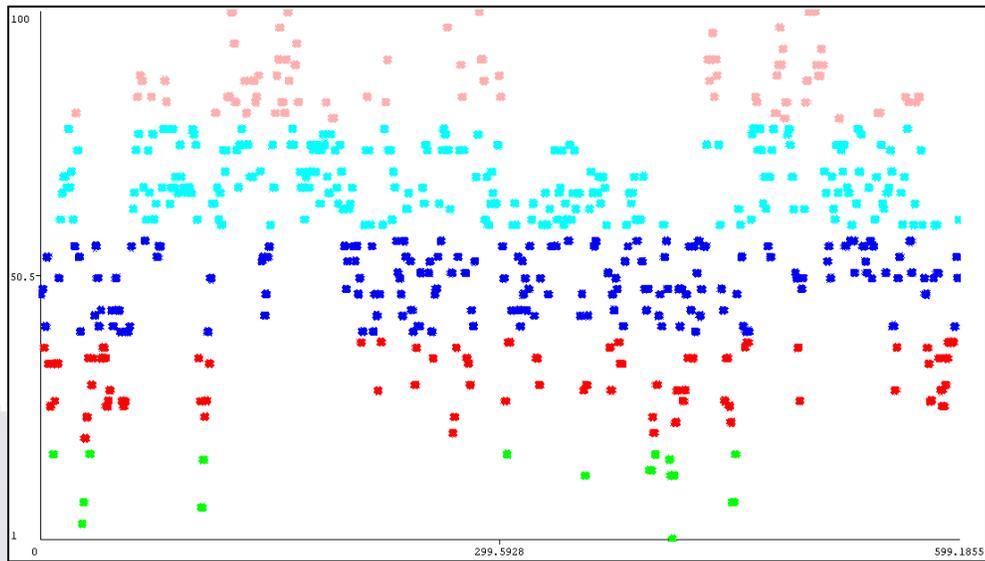


Figura 53 Gráfica de atención del participante ciego 5.

De los cinco participantes ciegos, el Participante 5 fue el que obtuvo un nivel de atención promedio más alto, con 58.71, cerca del rango “Bueno”. Sin embargo, al igual que el resto de los participantes ciegos, sigue permaneciendo dentro del rango “Regular”.

5.2 Participantes normovisuales.

Participante 3.

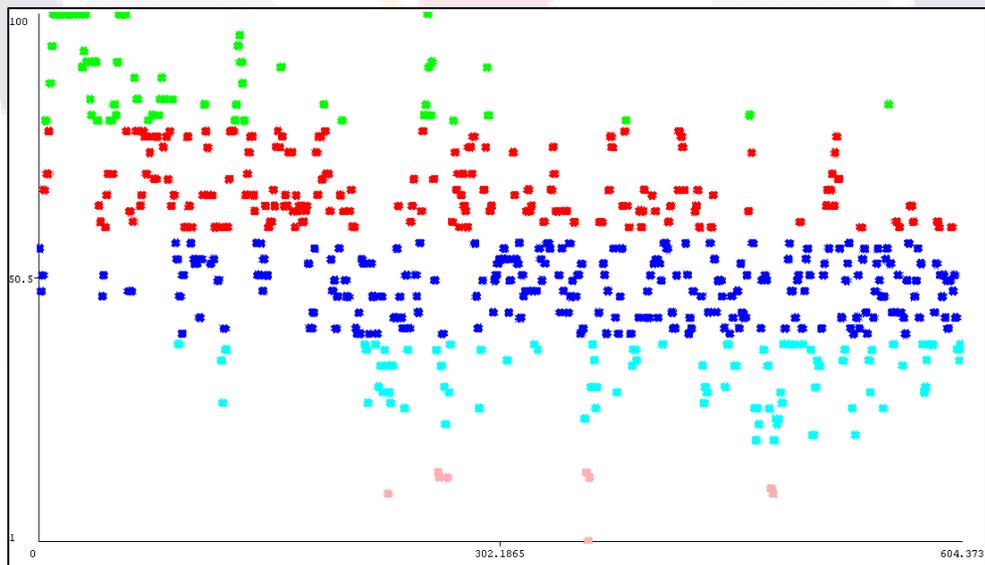


Figura 54 Gráfica de atención del participante normovisual 3.

El nivel promedio de atención de este participante fue 56.45. Si bien, sobre todo al inicio de la experimentación prácticamente no presentó niveles “Malos” ni “Muy Malos”, y estos últimos durante todo el registro no fueron tan relevantes, los niveles “Regular” y “Bueno” dominaron el registro.

Participante 4.

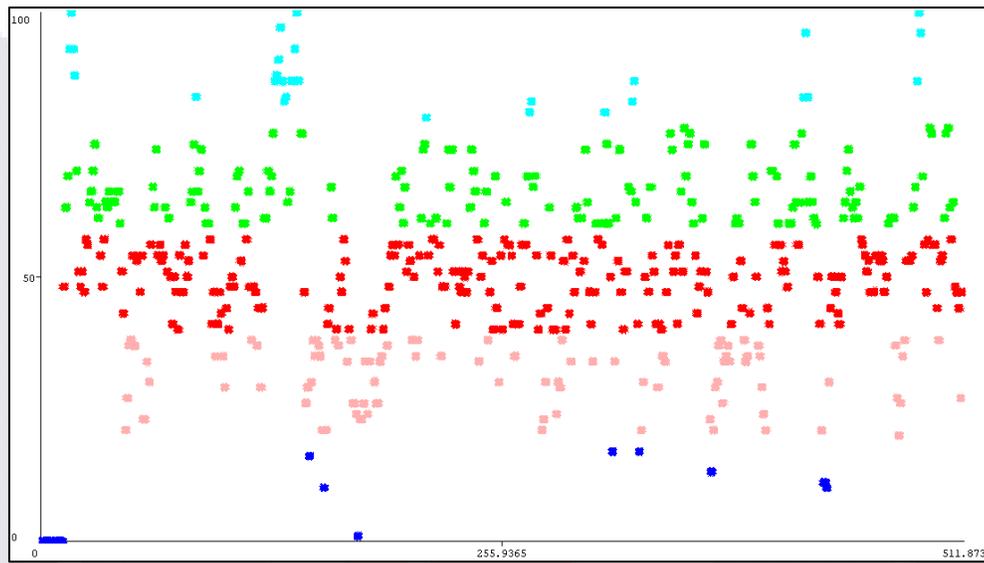


Figura 55 Gráfica de atención del participante normovisual 4.

El caso de este participante es muy similar al anterior, puesto que su nivel de atención promedio fue 51.29. Prácticamente, los niveles “Muy mala” y “Muy Buena” no están tan presentes, y la mayoría se concentra en “Regular” y “Buena”, con una presencia significativa de “Mala”.

Participante 5.

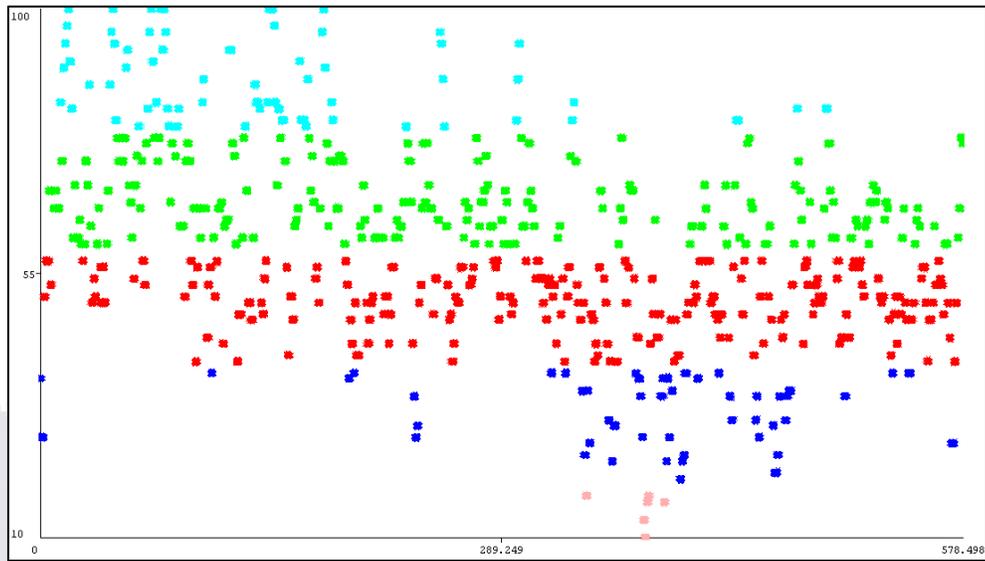


Figura 56 Gráfica de atención del participante normovisual 5.

En un caso similar al del Participante 2, los niveles de atención tuvieron un límite inferior por encima del 0, en este caso 10. Sus niveles de atención “Muy Mala” fueron casi imperceptibles, y mostró una tendencia descendente, es decir, comenzó con niveles “Muy Buenos” y progresivamente fue disminuyendo. Este Participante, tuvo una de las medias más altas de Atención, casi rozando el 60 con 59.156.

Participante 6.

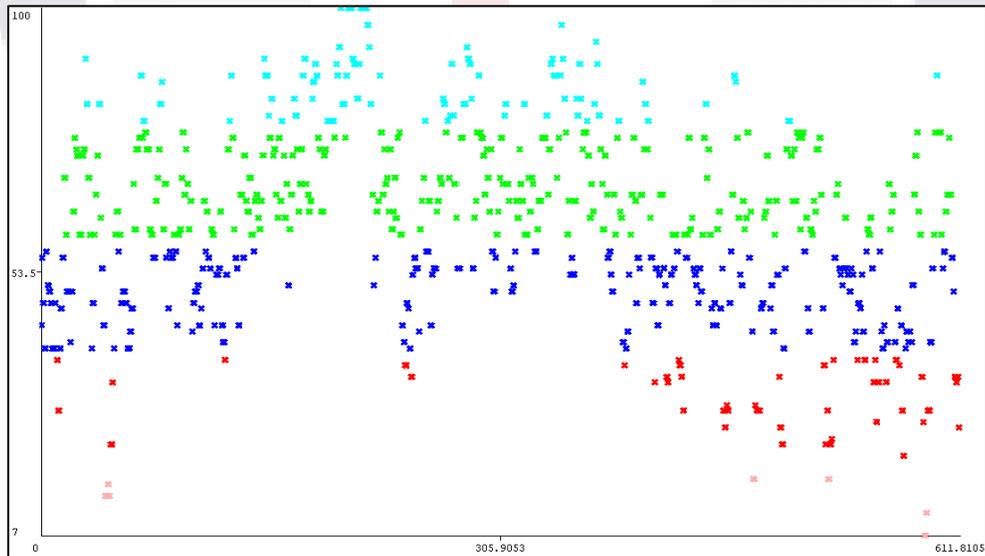


Figura 57 Gráfica de atención del participante normovisual 6.

Este participante fue el que presentó el nivel de atención más alto de todos (incluidos los participantes ciegos), con un promedio de atención de 61.9, logrando entrar en un rango durante todo el estudio de Nivel de atención “Buena”. De hecho, se percibe que lo correspondiente a nivel de atención “Muy mala”, las muestras son muy pocas, así como el límite inferior, que no baja más de 7.

Participante 7.

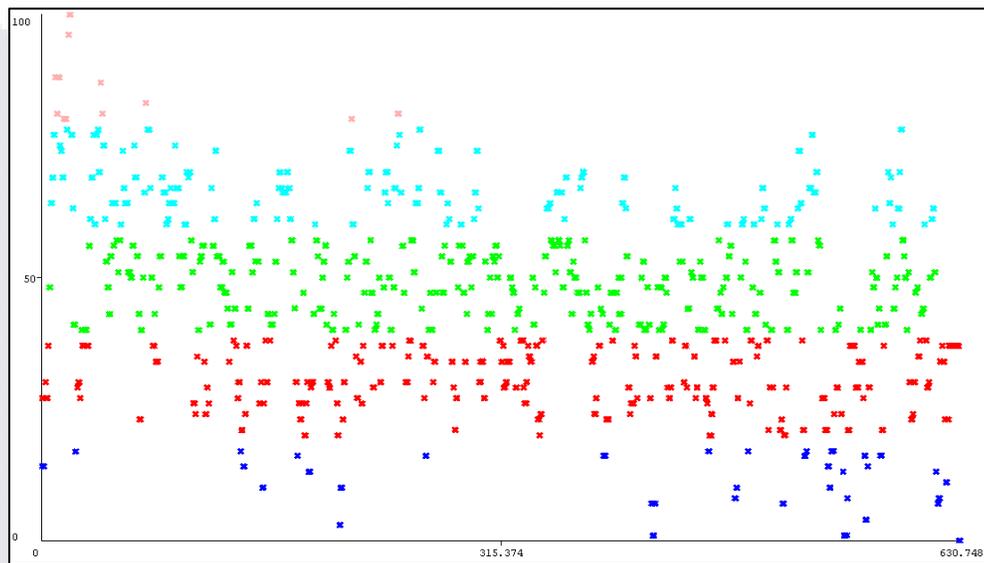


Figura 58 Gráfica de atención del participante normovisual 7.

Caso contrario al participante anterior, el nivel de atención promedio de este participante fue de 45.306, uno de los más bajos, aunque en momentos, muy pocos, alcanzó el nivel máximo, principalmente al inicio. La mayor parte de la experimentación, sus niveles estuvieron en “Mala” y “Regular”.

Participante 8.

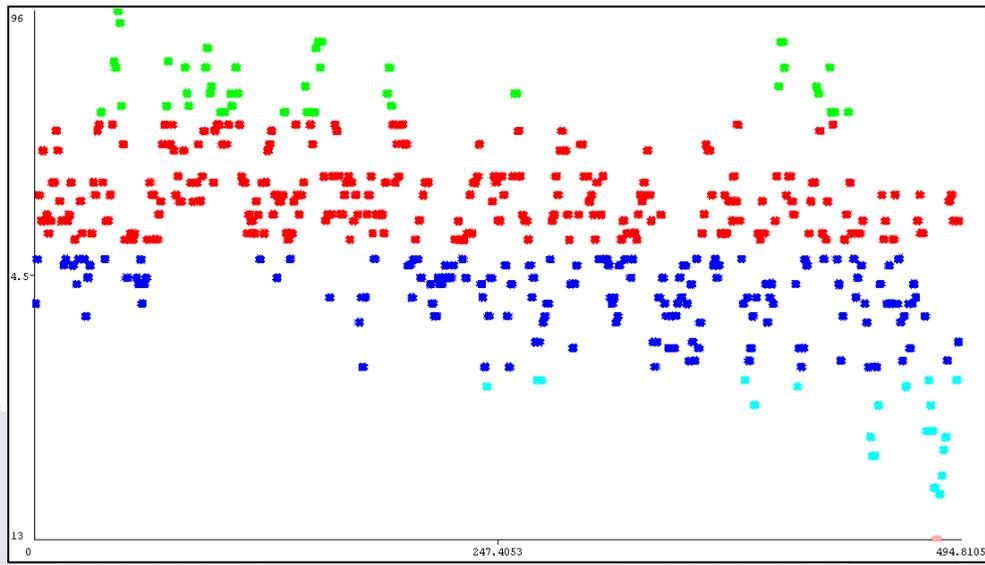


Figura 59 Gráfica de atención del participante normovisual 8.

Con un promedio de atención de 61.742, este participante fue el segundo más alto de todos (incluidos los participantes ciegos), un poco por debajo del 61.9 del Participante 6, siendo los únicos que consiguieron un nivel de atención “Buena” durante toda la experimentación. Como se observa en la gráfica, únicamente al final del registro, el nivel de atención cae.

Participante 9

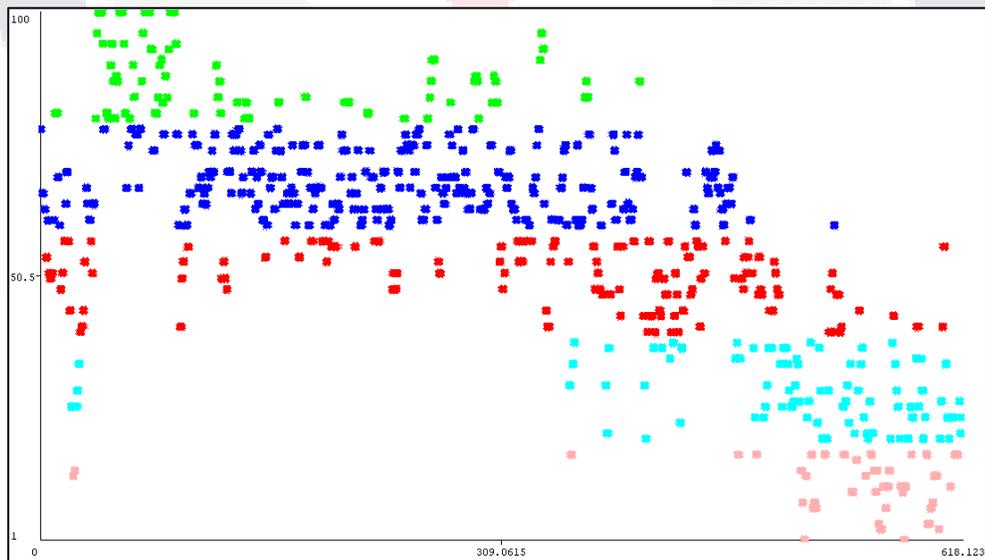


Figura 60 Gráfica de atención del participante normovisual 9.

En el registro de este participante se puede observar que empezó la experimentación muy bien, con niveles que llegaron al límite máximo de atención y se mantuvo en niveles principalmente “Buenos” durante poco más de la mitad; sin embargo, obtuvo un nivel de atención promedio de 56.364, el cual se explica por la caída a niveles “Regular”, “Mala” y “Muy mala” de atención hacia el final del registro.

Participante 10

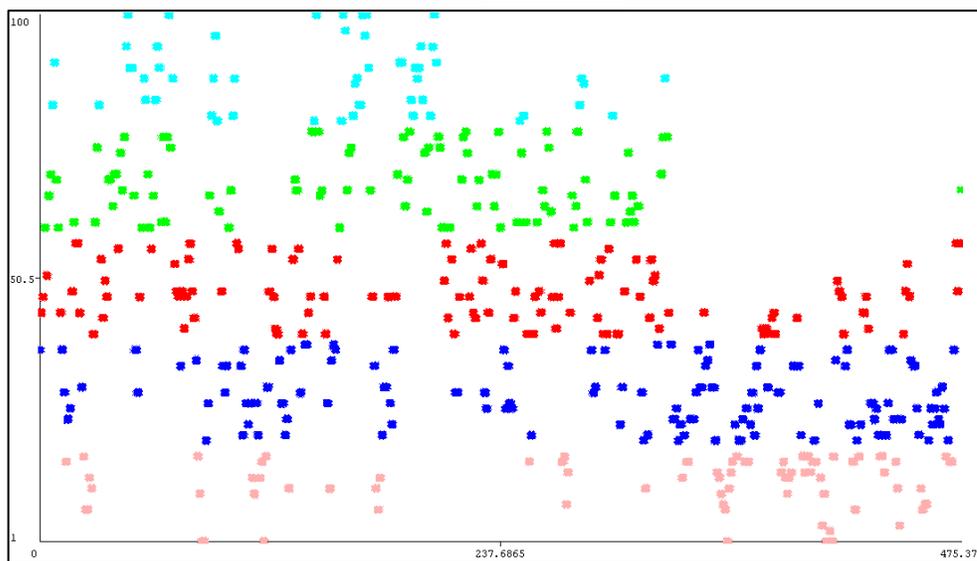


Figura 61 Gráfica de atención del participante normovisual 10.

Los niveles de atención de este participante fluctuaron bastante, desde alcanzar la atención máxima hasta la mínima durante casi la mitad del registro. Poco antes de la mitad, sus niveles empezaron a caer y a las tres cuartas partes, ya no hay prácticamente presencia de atención “Buena” y “Muy Buena”, de hecho, en un momento el nivel “Regular” también desaparece casi por completo. El nivel de Atención promedio de este participante fue de 44.657.

Anexo F. Relación del Nivel de Atención con los niveles Low Beta y High Beta de cada participante.

6.1 Participantes ciegos.

Participante 3.

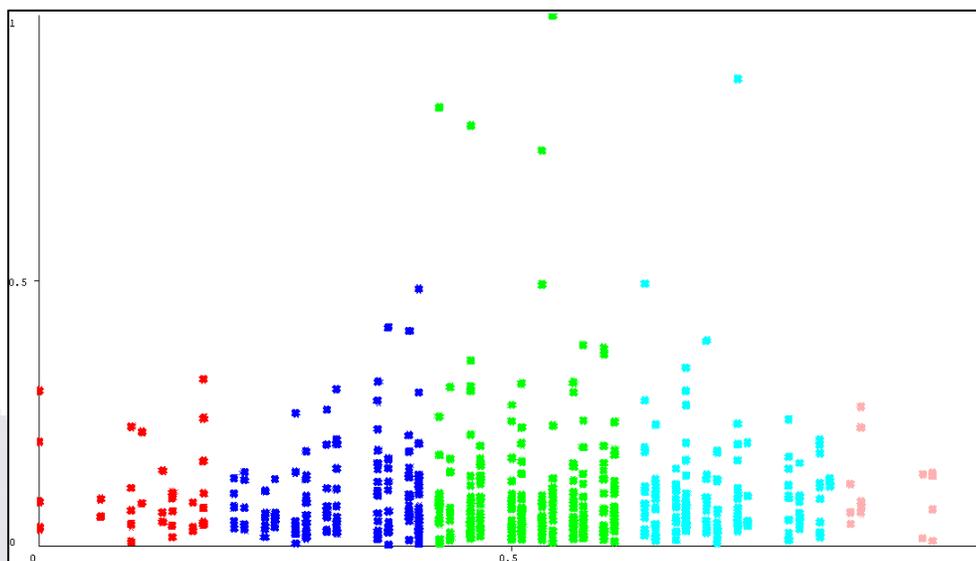


Figura 62 Gráfica de Low Beta del participante ciego 3.

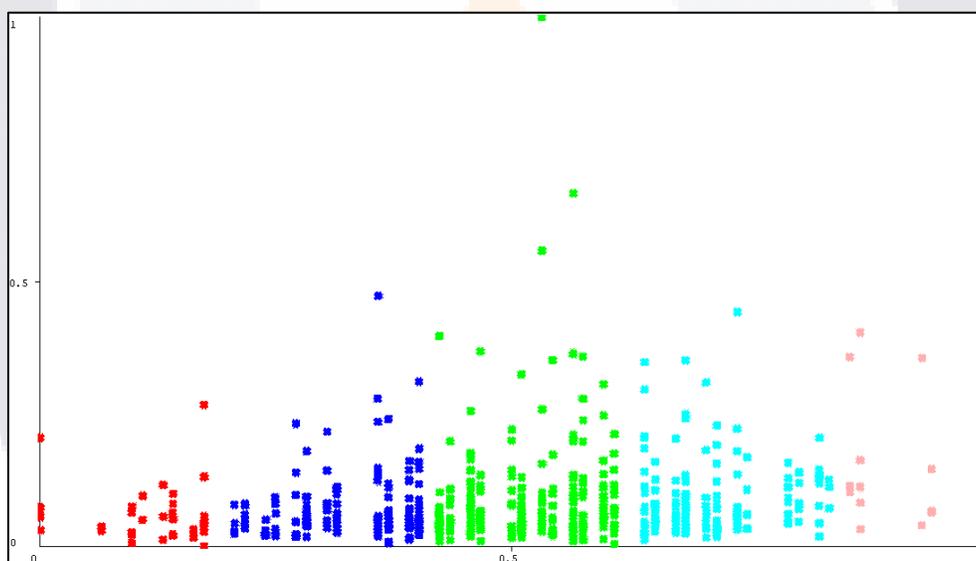


Figura 63 Gráfica de High Beta del participante ciego 3.

Participante 4.

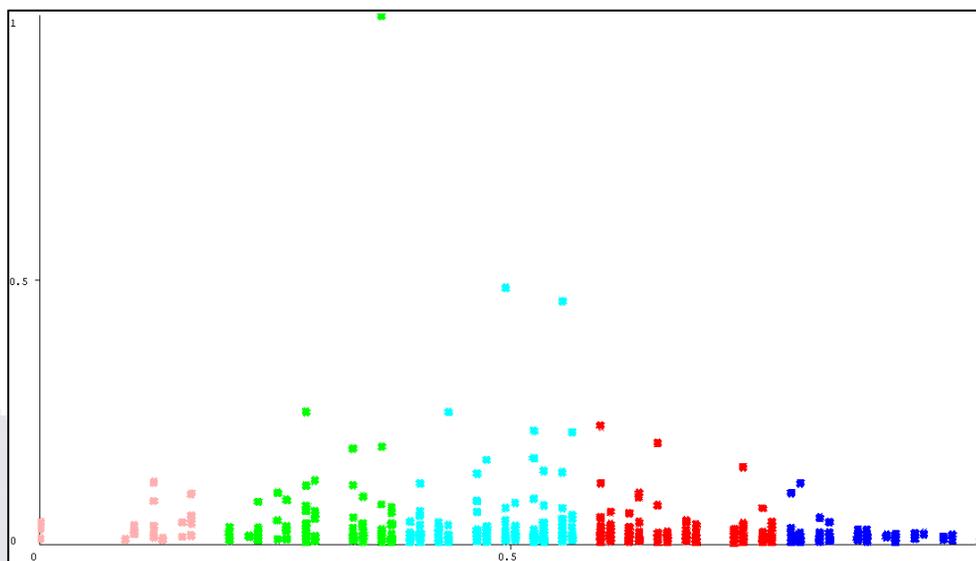


Figura 64 Gráfica de Low Beta del participante ciego 4.

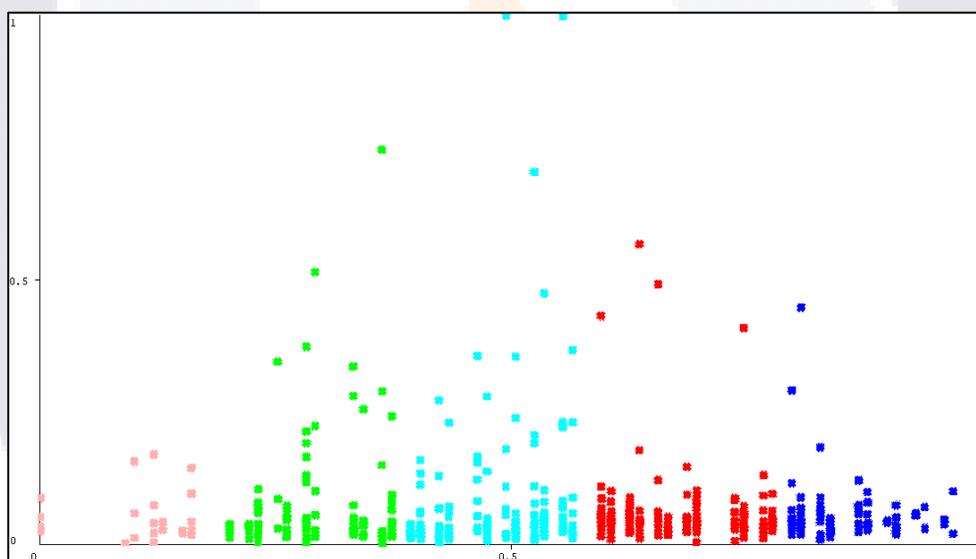


Figura 65 Gráfica de High Beta del participante ciego 4.

Participante 5.

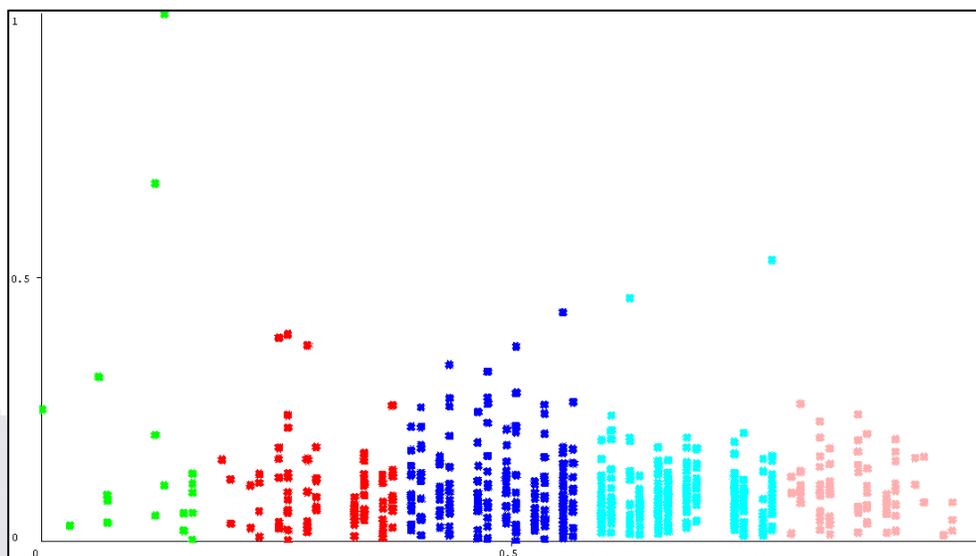


Figura 66 Gráfica de Low Beta del participante ciego 5.

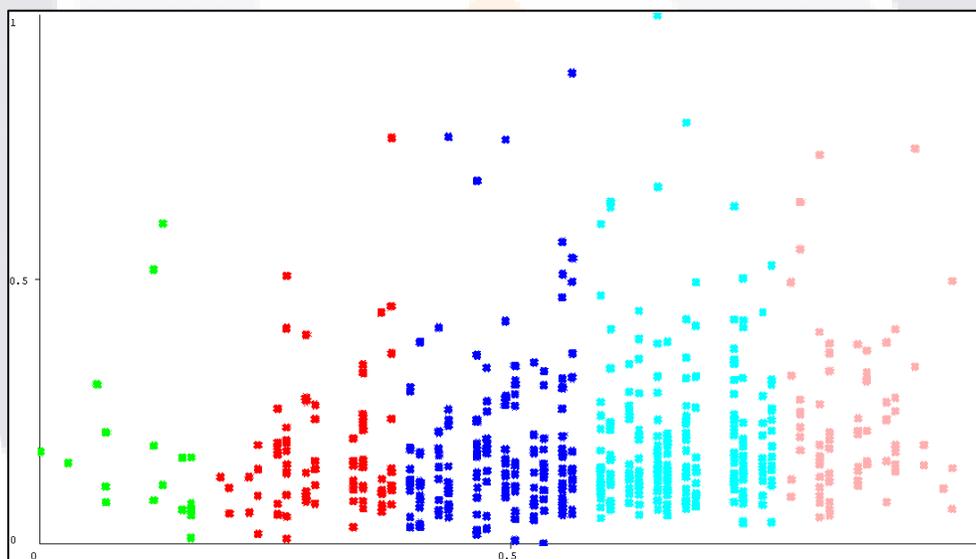


Figura 67 Gráfica de High Beta del participante ciego 5.

6.2 Participantes normovisuales.

Participante 3.

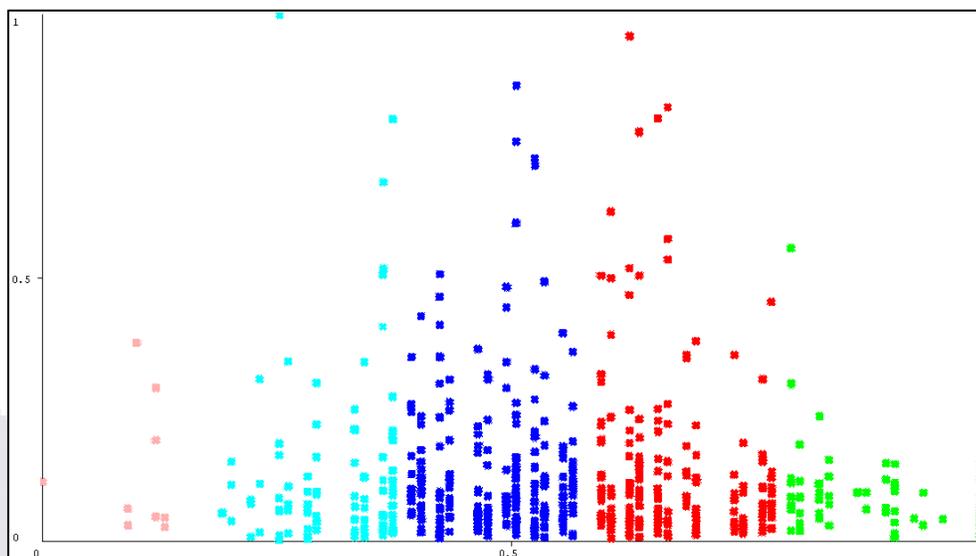


Figura 68 Gráfica de Low Beta del participante normovisual 3.

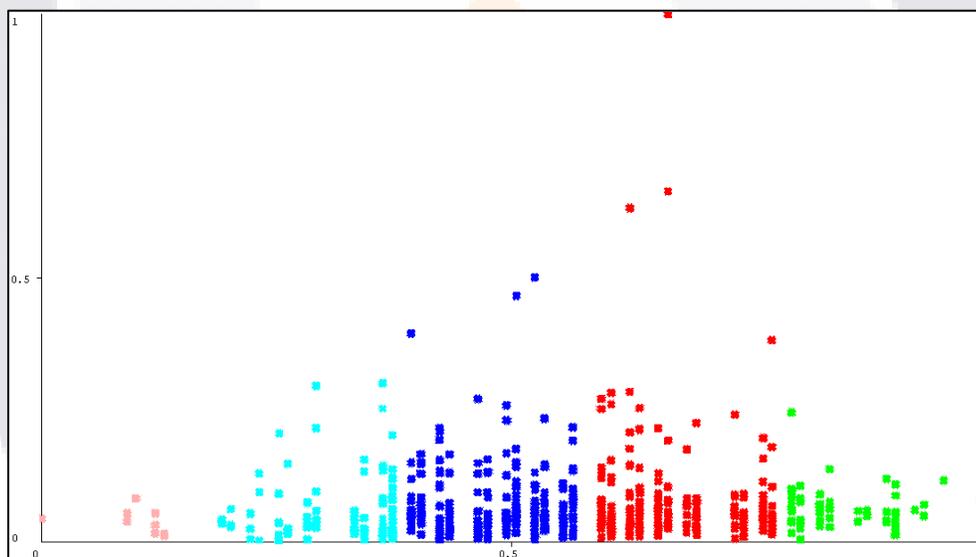


Figura 69 Gráfica de High Beta del participante normovisual 3.

Participante 4.

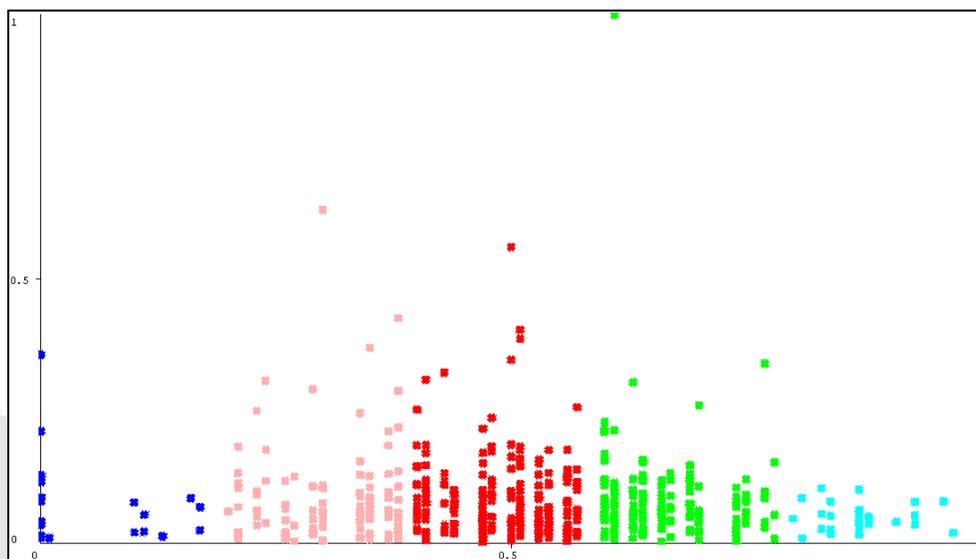


Figura 70 Gráfica de Low Beta del participante normovisual 4

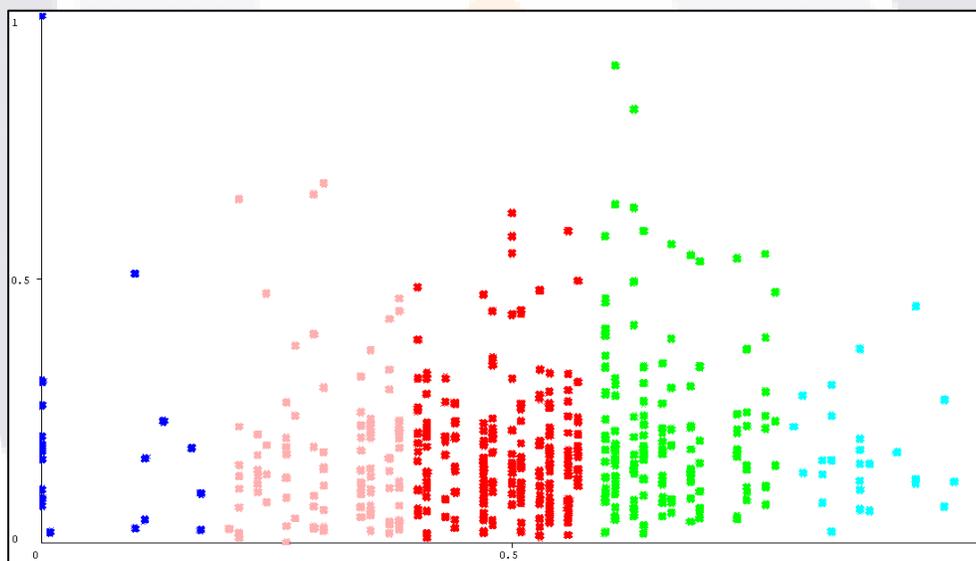


Figura 71 Gráfica de High Beta del participante normovisual 4.

Participante 5.

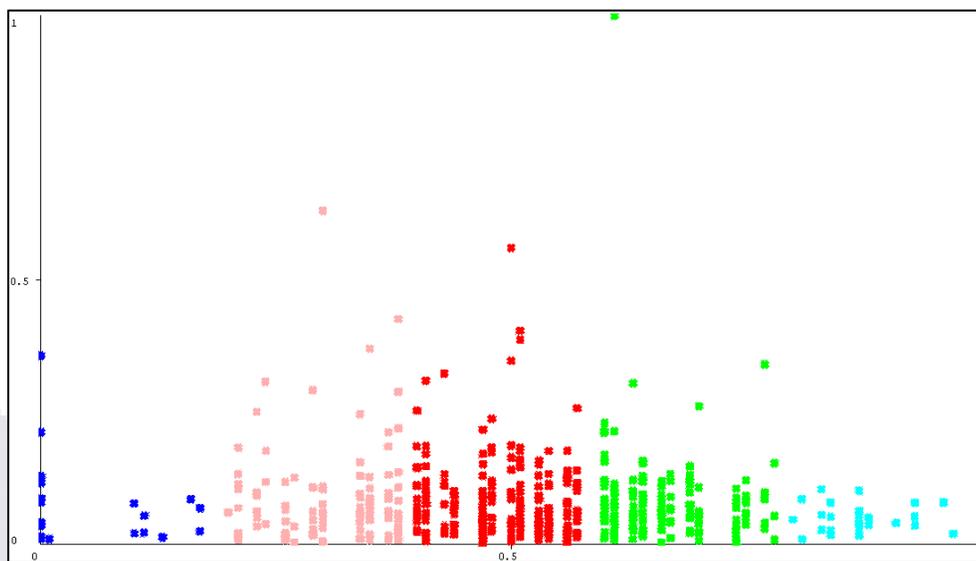


Figura 72 Gráfica de Low Beta del participante normovisual 5.

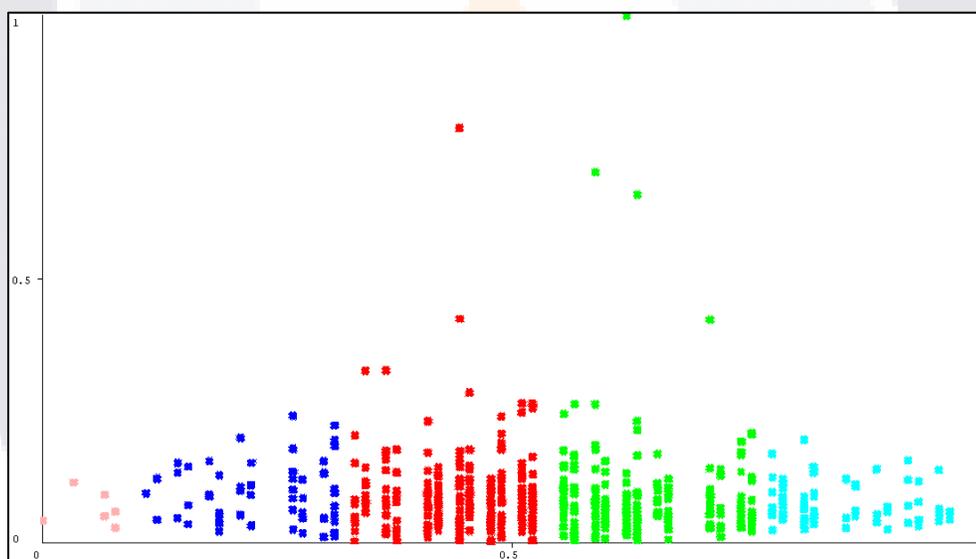


Figura 73 Gráfica de High Beta del participante normovisual 5.

Participante 6.

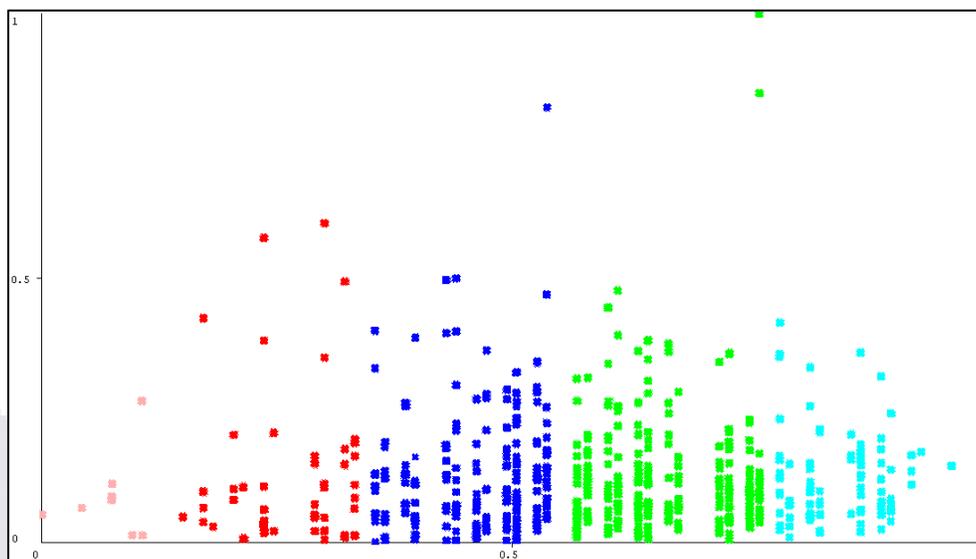


Figura 74 Gráfica de Low Beta del participante normovisual 6.

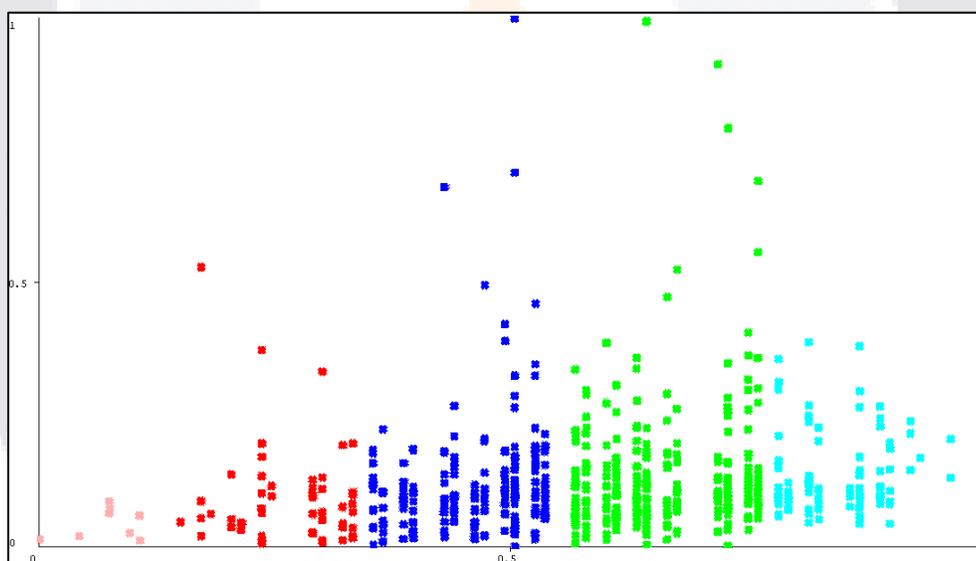


Figura 75 Gráfica de High Beta del participante normovisual 6.

Participante 7.

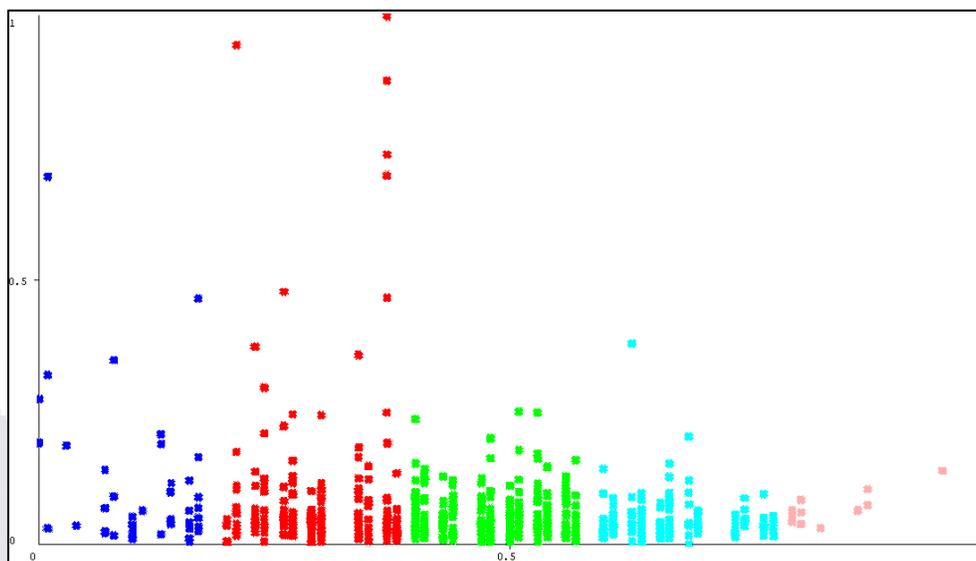


Figura 76 Gráfica de Low Beta del participante normovisual 7.

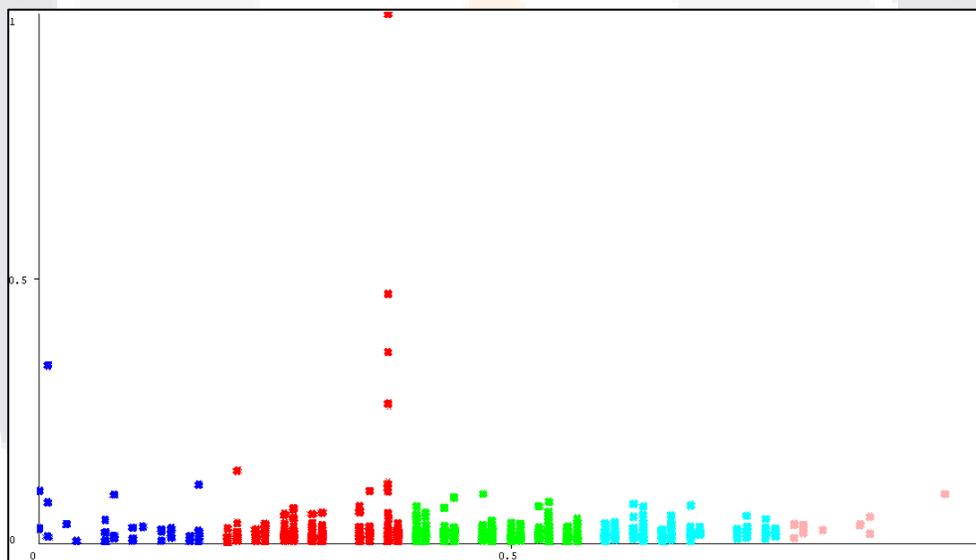


Figura 77 Gráfica de High Beta del participante normovisual 7.

Participante 8.

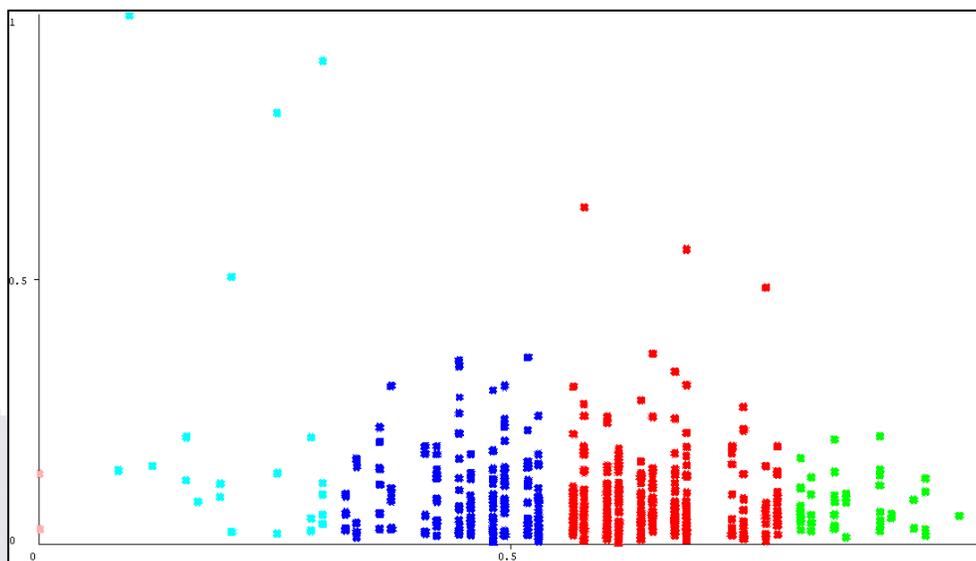


Figura 78 Gráfica de Low Beta del participante normovisual 8.

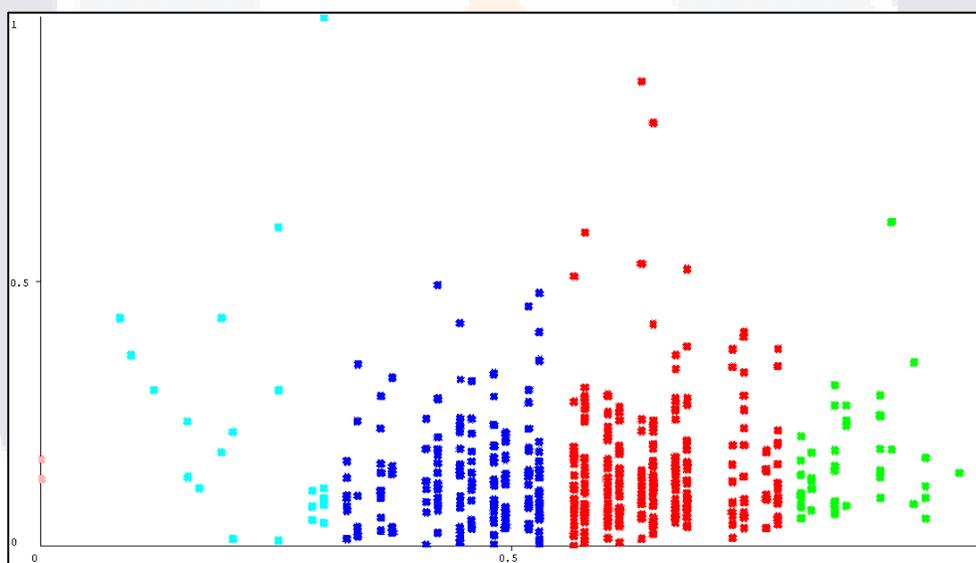


Figura 79 Gráfica de High Beta del participante normovisual 8.

Participante 9.

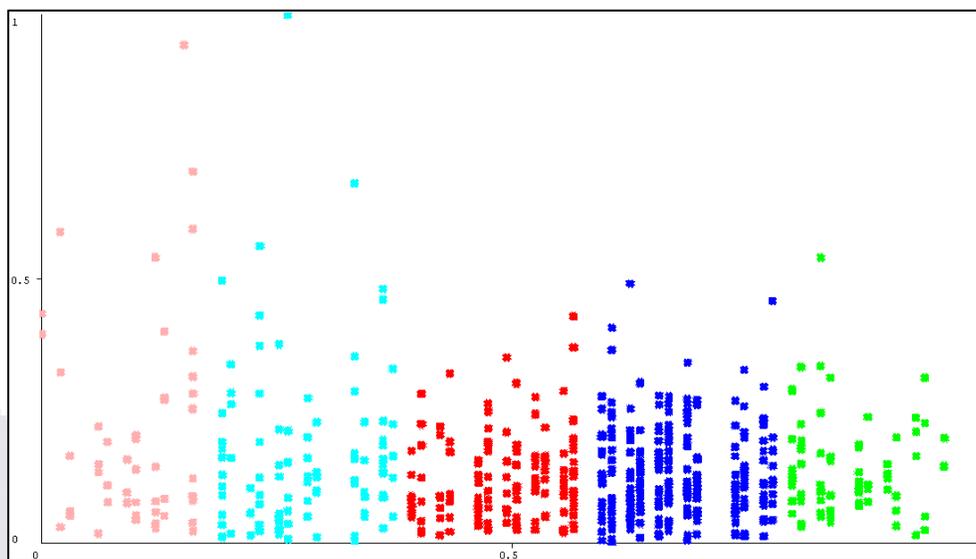


Figura 80 Gráfica de Low Beta del participante normovisual 9.

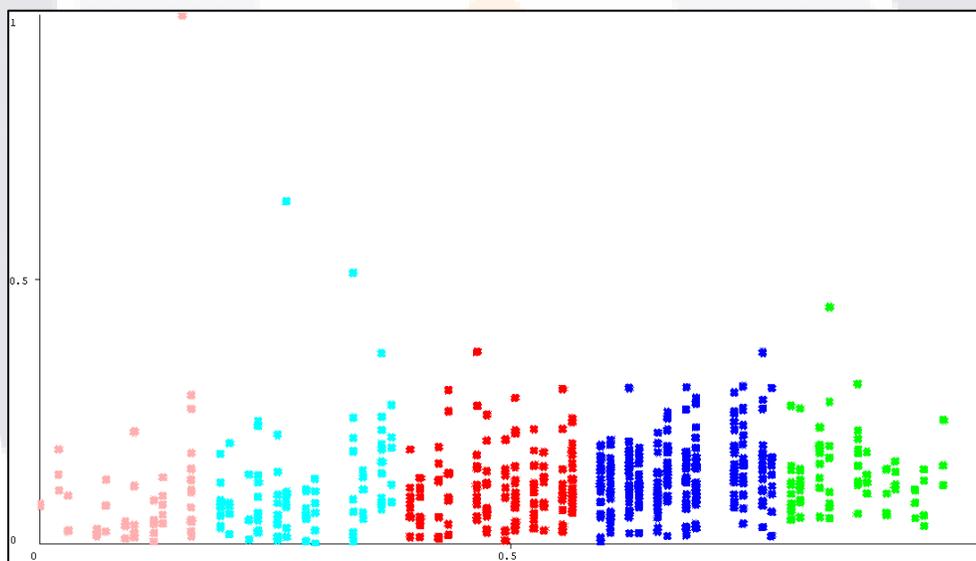


Figura 81 Gráfica de High Beta del participante normovisual 9.

Participante 10.

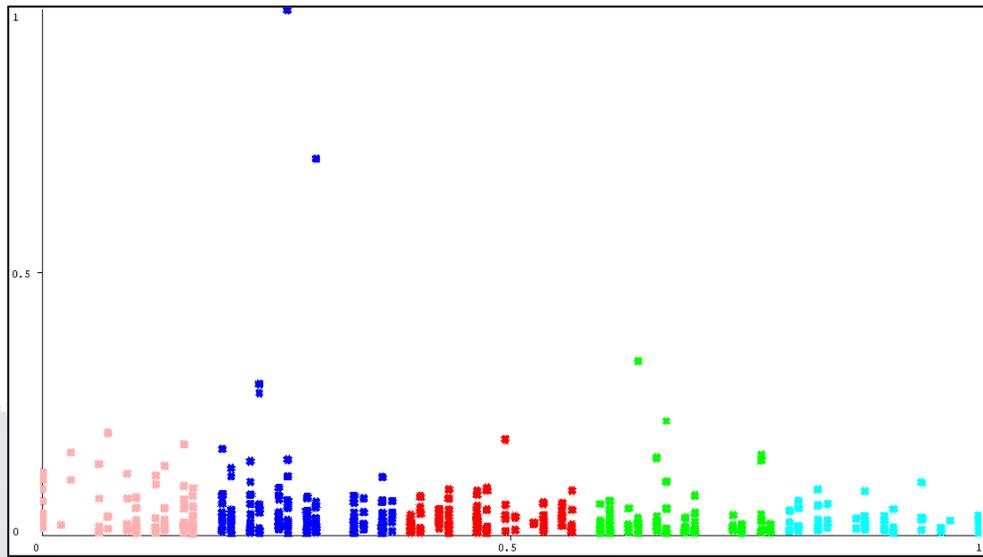


Figura 82 Gráfica de Low Beta del participante normovisual 10.

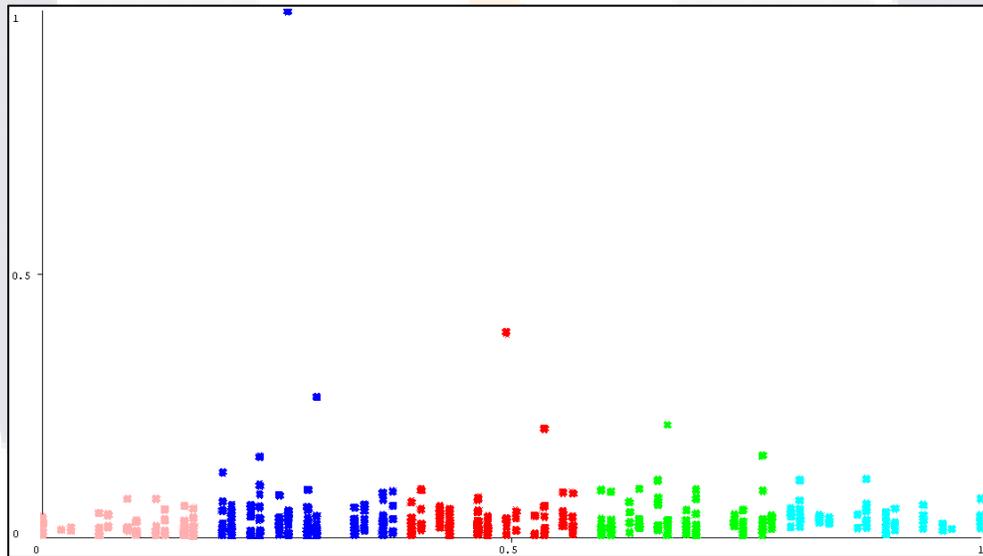


Figura 83 Gráfica de High Beta del participante normovisual 10.

Anexo G. *OpenViBE* y *WEKA*.

7.1 *OpenViBE*.

Software libre dedicado al diseño, prueba y uso de Interfaces Cerebro-Computadora (*BCI*, por sus siglas en inglés) desarrollado por *Mensia Tech* (Tech., 2019).

Características:

- Cuenta con Modulo de Adquisición (*OpenViBE Acquisition Server*), Diseño (*OpenViBE Designer*) y edición offline (*OpenViBE Tracker*).
- Compatible con gran variedad de *headsets* (incluido *MindWave Mobile*) de diferentes fabricantes.
- Diseño de procesos basado en bloques (Adquisición, Filtrado, Clasificación, Visualización, Escritura, Lectura, etc.), (Véase Figura 84 como ejemplo)
- Compatibilidad con otras plataformas como *Matlab* o *Python* para creación de scripts.
- Compatible con *Windows* y *Linux*.

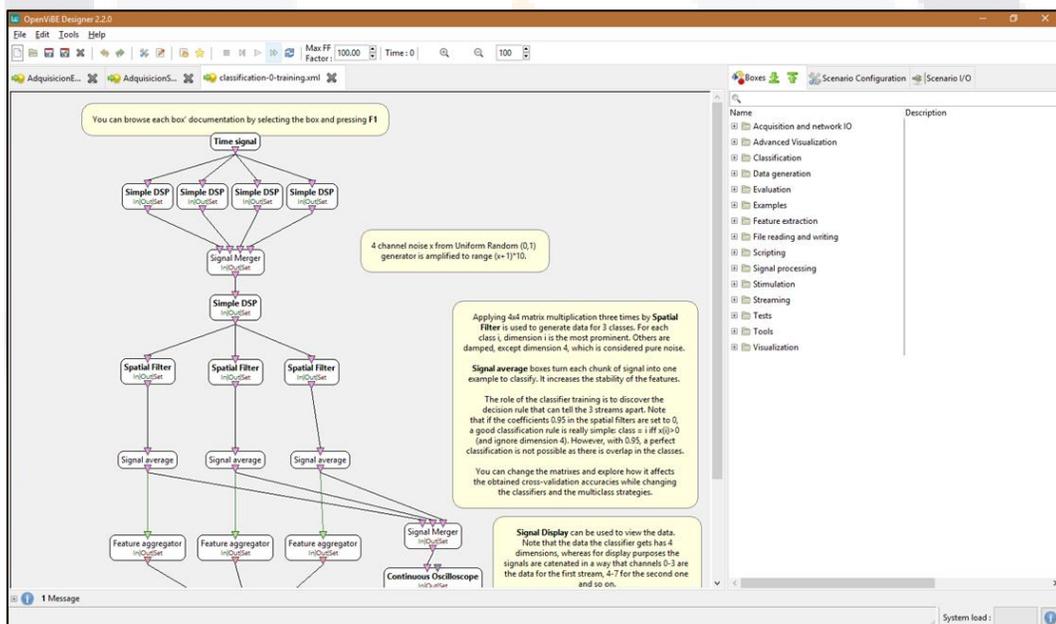


Figura 84 Captura de pantalla de escenario de ejemplo “classification-0-training”, incluido en el programa.

8.1.1 Adquisición.

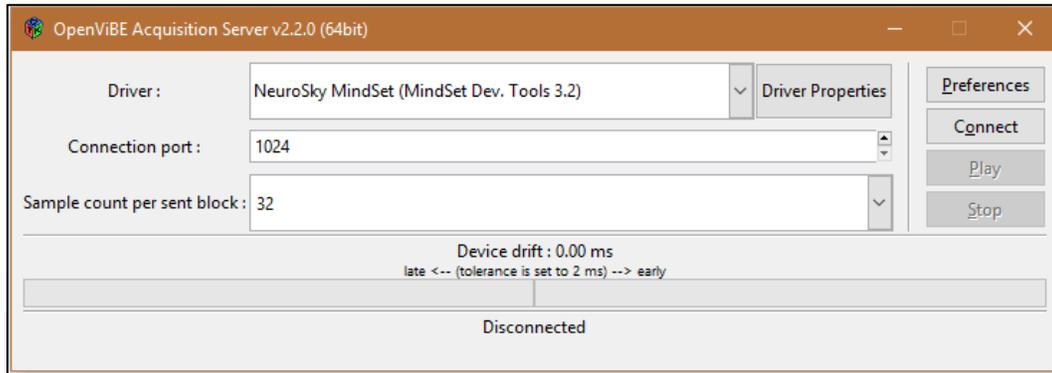


Figura 85 GUI *Acquisition Server* configurado para leer del *NeuroSky MindSet*.

Para adquirir las señales procedentes del *Headset*, se configura el *driver* de *NeuroSky MindSet* (compatible con la diadema *MindWave Mobile*) con una frecuencia de muestreo de 512Hz en el *OpenViBE Acquisition Server* (Figura 85), previa configuración vía Bluetooth del *Headset* con la *PC*.

Este programa está destinado a solo recibir las señales de los diferentes dispositivos que se configuren, más no a registrarlas, para ello, se utiliza el *OpenViBE Designer*.

8.1.2 Procesamiento y registro de las señales.

Una vez, se están enviando los datos por medio del *Acquisition Server* estos pueden ser manipulados en el *Designer*. Para esta experimentación, se procedió con el siguiente tratamiento de las señales:

- Recibir las señales mediante un cliente de adquisición
- Escribir directamente el registro del EEG Crudo (*Raw*) con los demás atributos que lo acompañan, los cuales son: Tiempo, Época, Potencias de cada una de las señales por banda de frecuencia, nivel de atención y nivel de meditación en un archivo *.csv*.
- Dividir por banda de frecuencia, las ondas cerebrales (*Delta, Theta, Alpha, Beta* y *Gamma*), procedentes del Canal 1, el cual registra el EEG Crudo.
- Escribir cada onda cerebral en un archivo *.csv*.

NOTA: Posteriormente, las ondas cerebrales se añaden al mismo *dataset* del EEG Crudo mediante *Excel*. Esto se realiza de esta manera debido a la imposibilidad de *OpenViBE* para guardar registros múltiples en un solo archivo tipo *.csv*.

7.2 WEKA (Waikato Environment for Knowledge Analysis).

WEKA es un *software* libre desarrollado en *Java* por la Universidad de Waikato en Nueva Zelanda, consiste en una colección de algoritmos de *Machine Learning* para tareas de Minería de Datos (*Data Mining*) (WEKA, 2019).

Características:

- Contiene herramientas para la preparación, clasificación, regresión, clusterización, asociación y visualización de datos.
- Cuenta con aplicaciones como: *Explorer*, *Experimenter*, *KnowledgeFlow*, *Workbench* y *SimpleCLI* (Figura 86)
- Soporta algoritmos de Aprendizaje Profundo (*Deep Learning*)
- Cuenta con una interfaz gráfica muy agradable con el usuario que le permite hacer análisis aún sin conocimientos de un lenguaje de programación en específico.

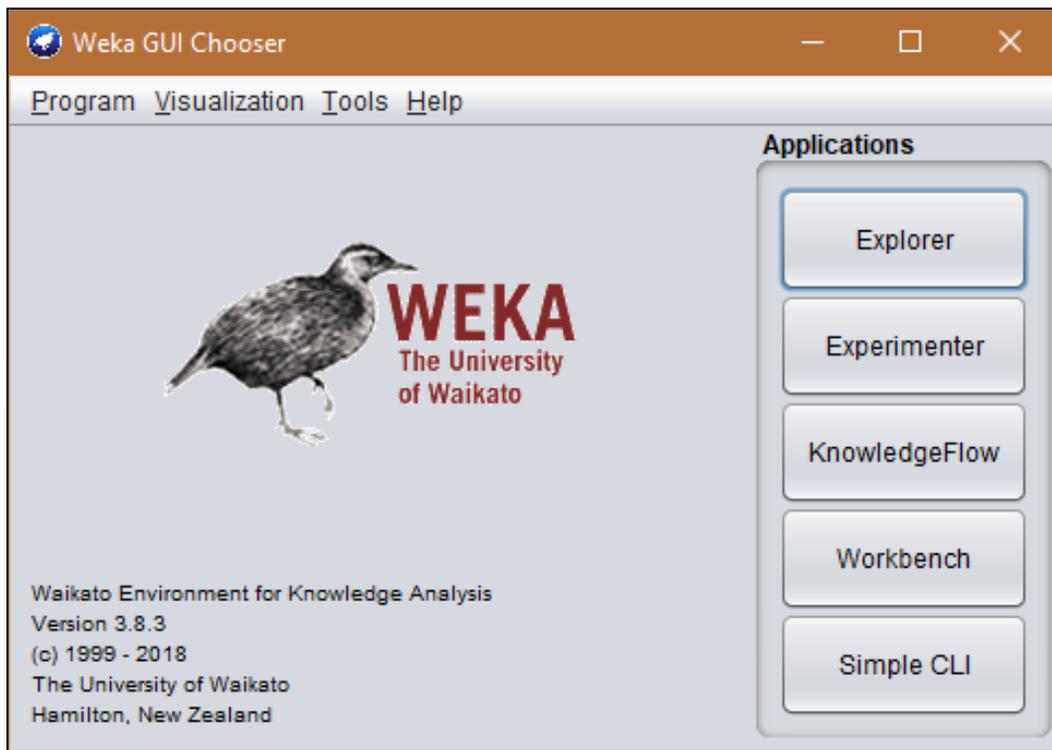


Figura 86 Captura de pantalla *WEKA GUI Chooser*.

Anexo H. Casos de Estudio

8.1 Experimento: Aprendizaje Explícito e Implícito.

8.1.1 Diseño de experimento.

Mediante un juego de razonamiento matemático llamado “Juego de las 12 monedas” se evalúa el aprendizaje explícito.

El juego es propuesto por el matemático español Eduardo Saenz de Cabezón en una conferencia llamada “Las matemáticas nos hacen más libres y menos manipulables” (Cabezón, 2018).

El juego se puede hacer en una pizarra o bien con monedas (de ahí su nombre), consiste en un juego de competencia de uno contra uno en el que se busca retirar la última moneda (o el último par de monedas) para ganar.

8.1.2 Procedimiento:

- Se comienza siempre con doce monedas repartidas en forma circular.

- Cada jugador debe retirar una o dos monedas por turno, con la condición de que, si se decide retirar dos monedas, estas deben estar juntas (contiguas).
- El jugador que retire la última, (o el último par) gana la partida.

Es un juego bastante sencillo que, jugado de una manera en específica (técnica), siempre da la victoria al segundo lugar.

Esta manera de jugar es cediendo el primer turno al contrincante y siempre copiar sus movimientos en espejo, por ejemplo, si el jugador 1, decide retirar una piedra, el jugador 2 debe retirar una también del lado opuesto a la que este la retiró.

Con este método de juego está garantizada la victoria siempre para el segundo jugador.

Dado este preámbulo, se buscaron participantes con ceguera (personas del DIF municipal de Aguascalientes) que quisieran jugar con alguno de los evaluadores (alumnos de pregrado participantes del Verano de Investigación científica Delfín) con el previo consentimiento del participante plasmado en una carta donde aceptaba que durante el juego, se realizaría el registro de las ondas cerebrales del concursante con ceguera, y que a la postre, sus señales serían analizadas con fines académicos y de investigación.

Para poder adaptar el juego de mejor manera para las personas con ceguera, en lugar de monedas, se utilizaron piedras, siendo la temática del juego, la misma.

Una representación simple del juego se observa en la Figura 87.

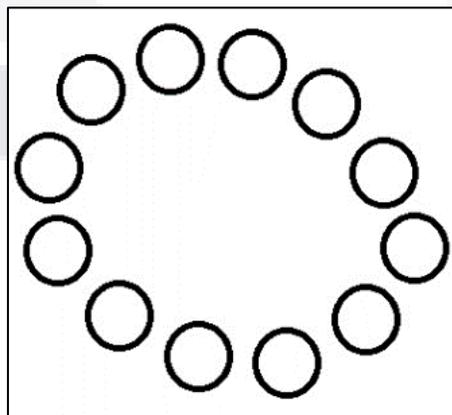


Figura 87 Representación del Juego de las Doce Monedas

8.1.3 Medición de aprendizaje explícito

Para generar un aprendizaje explícito durante el juego, el concursante debe estar consiente que va a aprender algo en específico, por lo cual, el conocimiento involucrado para esta actividad fue de hecho, la forma ganadora garantizada para el segundo participante:

- Se juega una primera partida de evaluador vs concursante sin explicar la técnica ganadora para el segundo jugador, invitando como primer paso, que el concursante sea quien arranque el juego (mientras que el evaluador aplica esta técnica).
- Dado que la técnica es infalible siempre que el jugador dos la siga al pie de la letra, el evaluador le ganará al concursante sin dificultad.
- Una vez terminada la primera partida, se explica detalladamente la técnica al concursante y se le invita a que la ponga en práctica en la partida siguiente para corroborar que ganará (aunque bien el concursante puede no usarla y querer jugar a su manera, con lo cual no se garantiza su victoria)
- Durante la partida, se adquieren las señales EEG del concursante, posteriormente, se realiza un análisis de esta, identificando los tiempos de cada etapa del juego (comienzo, explicación del patrón, inicio del segundo juego).

8.1.4 Herramientas utilizadas

- El dispositivo BCI utilizado para la adquisición de las señales EEG es la diadema *MindWave* de *NeuroSky* (NeuroSky, 2015b).
- El *software* para adquirir las señales es *NeuroExperimenter* (disponible en el sitio web del fabricante *NeuroSky* de manera gratuita, Figura 88) (Mellender, 2018)

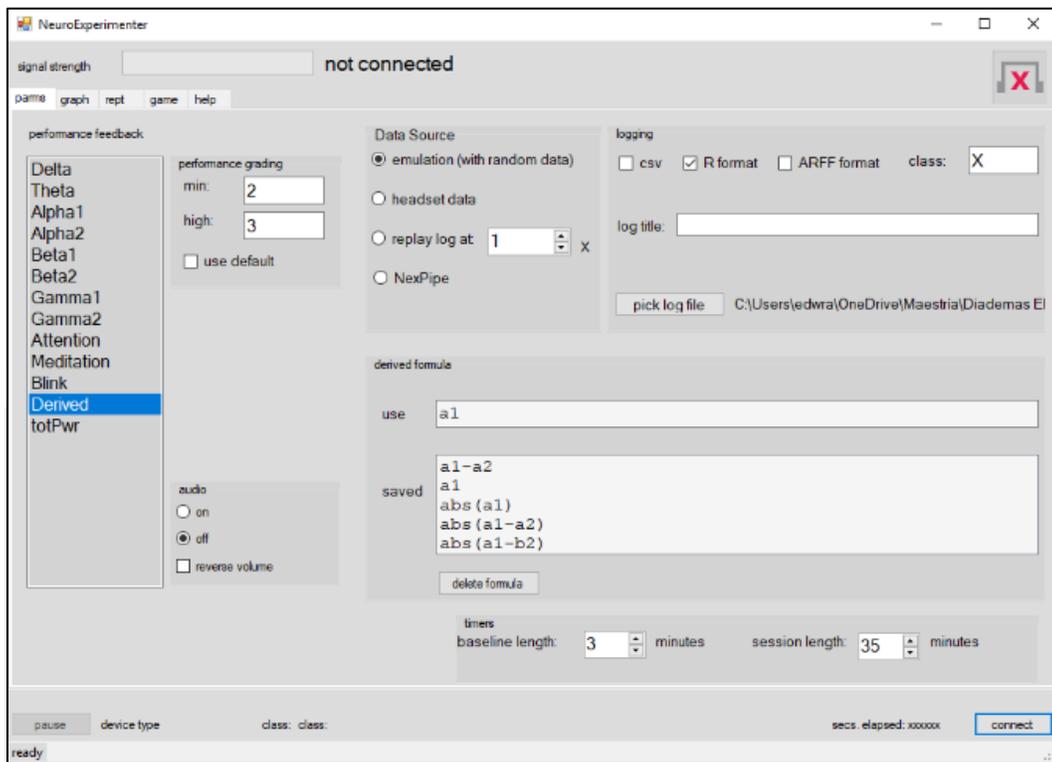


Figura 88 Interfaz principal de *NeuroExperimenter*.

- *Microsoft Excel* (para hacer la graficación y comparación de las señales, sin embargo, puede utilizarse cualquier otro programa compatible con archivos .csv como *Matlab*).

8.1.5 Métricas para el aprendizaje explícito.

- “En las tareas explícitas, la sincronía alfa/beta aumenta con el aprendizaje y disminuye a partir de entonces” (Loonis, Brincat, Antzoulatos, & Miller, 2017).
- "(Lo anterior) ... podría reflejar la construcción de un modelo de la tarea". "Y luego, una vez que se aprende la tarea, los ritmos alfa-beta caen, porque el modelo ya está construido" (Loonis et al., 2017).

NOTA: Cabe señalar que la experimentación realizada por el Dr. Miller, fue con animales, por lo cual, las métricas que él plantea tratan de ser corroboradas con esta experimentación con humanos.

8.1.6 Implementación

Para llevarse a cabo la experimentación, se diseñó un proceso guía, (Figura 89)

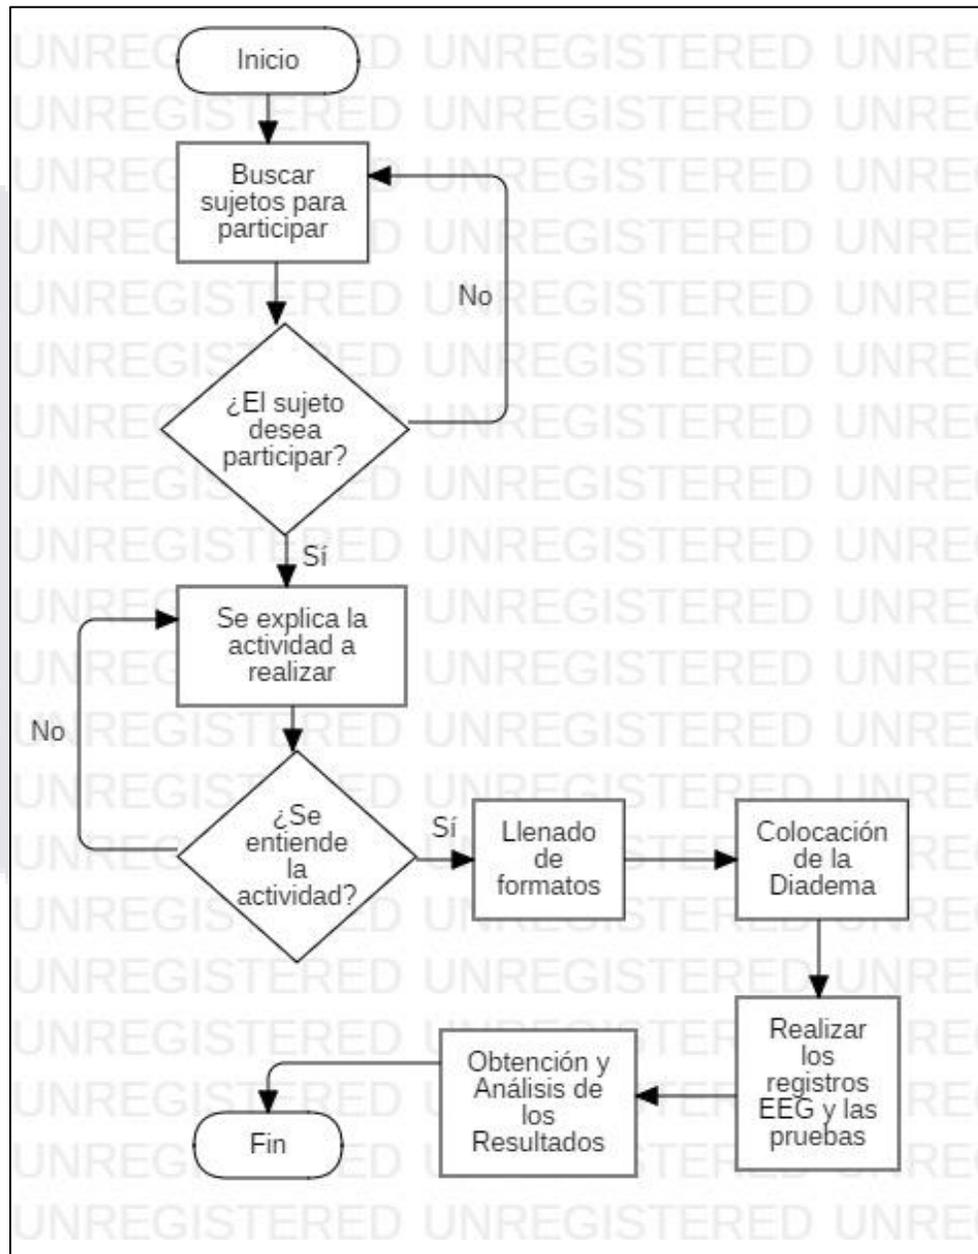


Figura 89 Diagrama de Flujo sobre el Proceso de Experimentación

8.1.7 Medición de aprendizaje implícito

NOTA: Para el caso de la medición del aprendizaje implícito, se utilizaron las mismas herramientas y modelo de experimentación, únicamente cambiando el juego de las “12 monedas” por la reproducción de una canción infantil que explica las partes del cuerpo en inglés.

8.1.8 Participantes Ciegos.

Participante 1

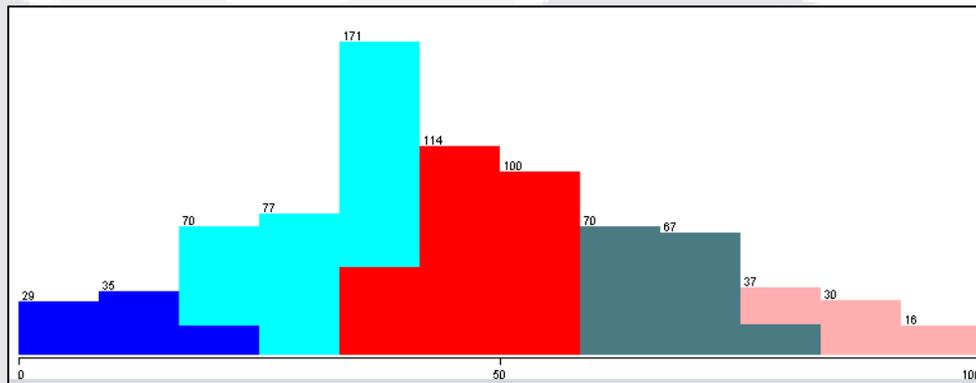


Figura 90 Histograma del participante ciego 1 (AE).

Tabla 24 Datos del participante ciego 1 (AE).

ID	C1
Sexo	Mujer
Tipo de Actividad	<i>Aprendizaje Explícito</i>
Atención promedio	45.801

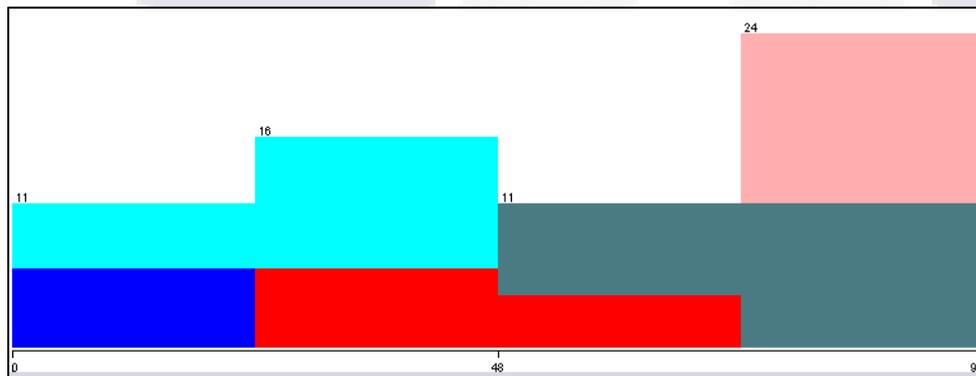


Figura 91 Histograma del participante ciego 1 (AI).

Tabla 25 Datos del participante ciego 1 (AI).

ID	C1
Sexo	Mujer
Tipo de Actividad	<i>Aprendizaje Implícito</i>
Atención promedio	54.839

Participante 2

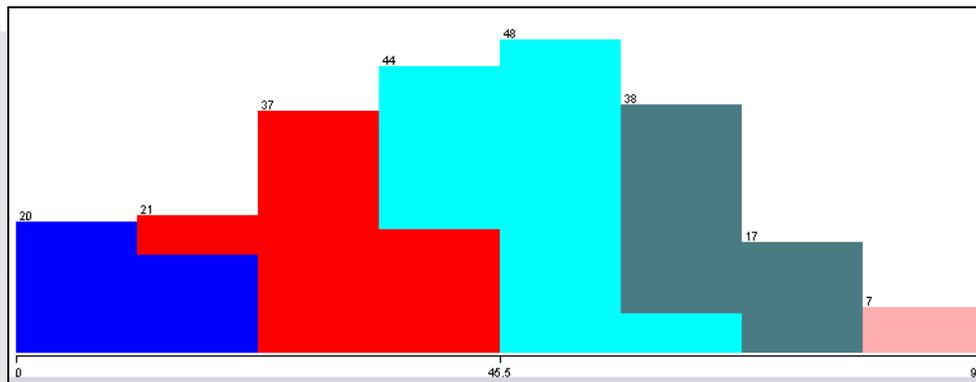


Figura 92 Histograma del participante ciego 2 (AE).

Tabla 26 Datos del participante ciego 2 (AE).

ID	C2
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Explícito</i>
Atención promedio	42.819

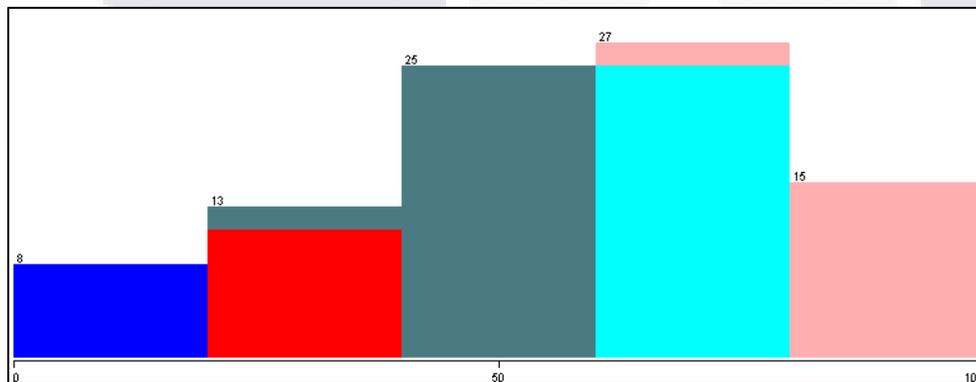


Figura 93 Histograma del participante ciego 2 (AI).

Tabla 27 Datos del participante ciego 2 (AI).

ID	C2
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Implícito</i>
Atención promedio	56.795

Participante 3

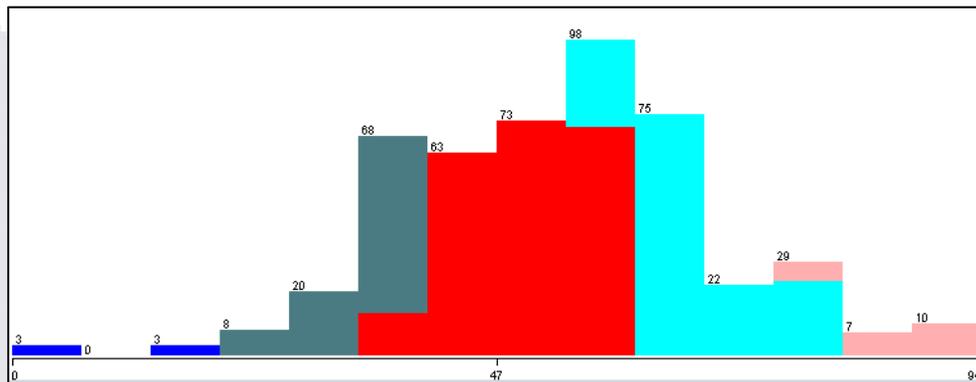


Figura 94 Histograma del participante ciego 3 (AE).

Tabla 28 Datos del participante ciego 3 (AE).

ID	C3
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Explícito</i>
Atención promedio	52.965

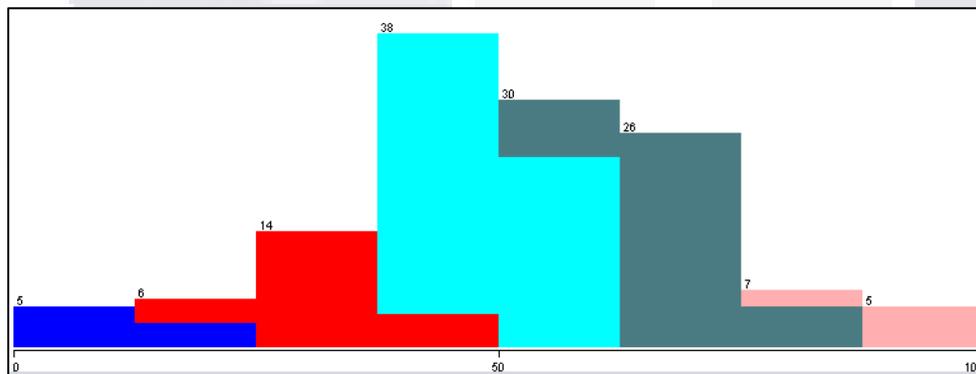


Figura 95 Histograma del participante ciego 3 (AI).

Tabla 29 Datos del participante ciego 3 (AI).

ID	C3
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Implícito</i>
Atención promedio	51.4

Participante 4

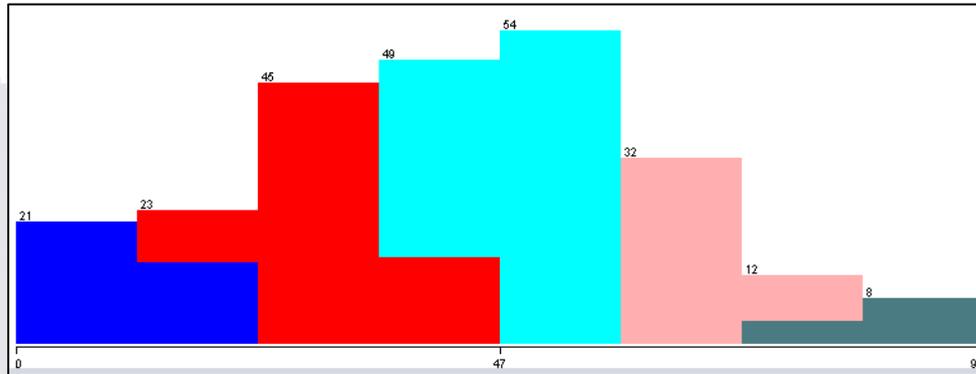


Figura 96 Histograma del participante ciego 4 (AE).

Tabla 30 Datos del participante ciego 4 (AE).

ID	C4
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Explícito</i>
Atención promedio	42.393

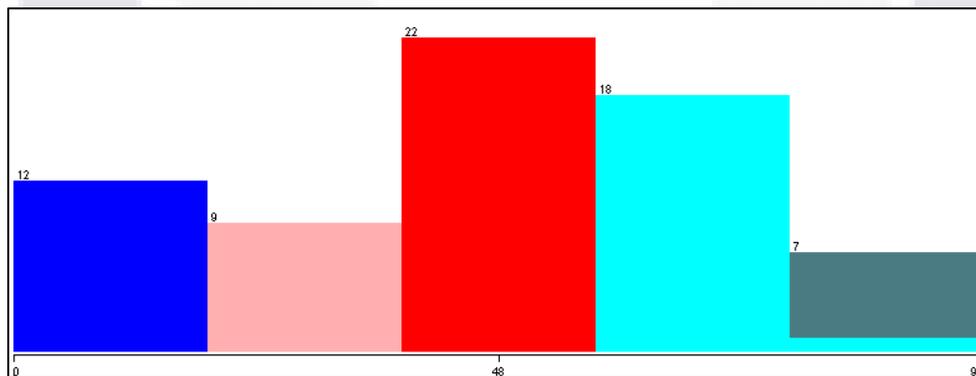


Figura 97 Histograma del participante ciego 4 (AI).

Tabla 31 Datos del participante ciego 4 (AI).

ID	C4
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Implícito</i>
Atención promedio	46.721

Participante 5

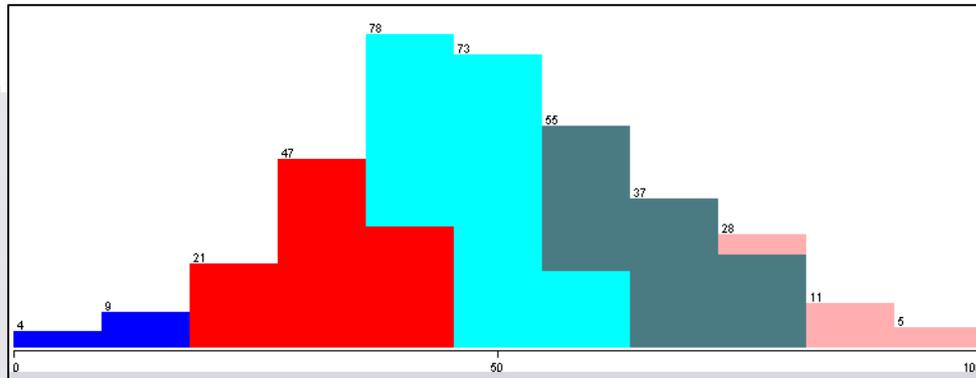


Figura 98 Histograma del participante ciego 5 (AE).

Tabla 32 Datos del participante ciego 5 (AE).

ID	C5
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Explícito</i>
Atención promedio	49.747

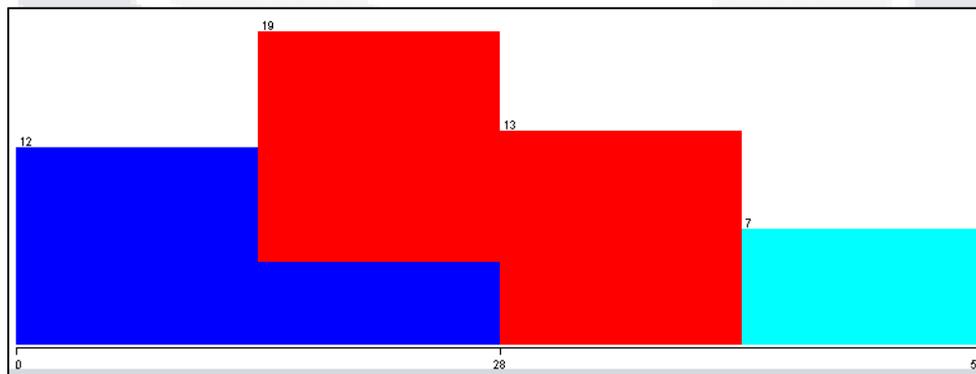


Figura 99 Histograma del participante ciego 5 (AI).

Tabla 33 Datos del participante ciego 5 (AI).

ID	C5
Sexo	Hombre
Tipo de Actividad	<i>Aprendizaje Implícito</i>
Atención promedio	25.588

8.1.9 Participantes Normovisuales

Participante 1

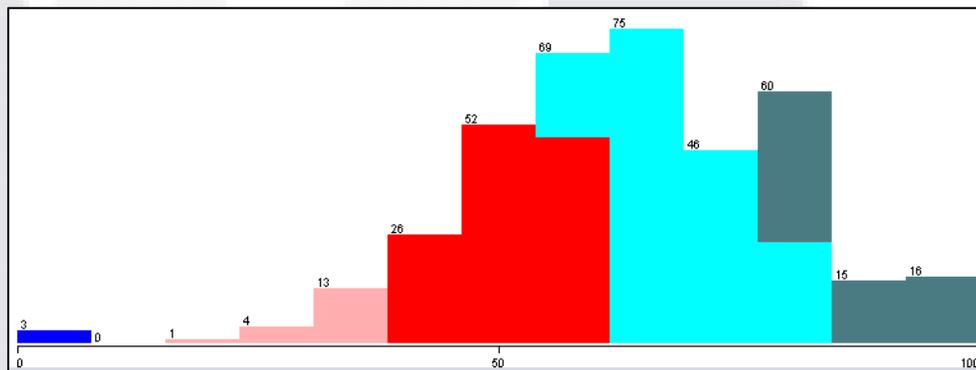


Figura 100 Histograma del participante normovisual 1 (AE).

Tabla 34 Datos del participante normovisual 1 (AE).

ID	N1
Sexo	Mujer
Tipo de Actividad	<i>Aprendizaje Implícito Canción</i>
Atención promedio	63.632

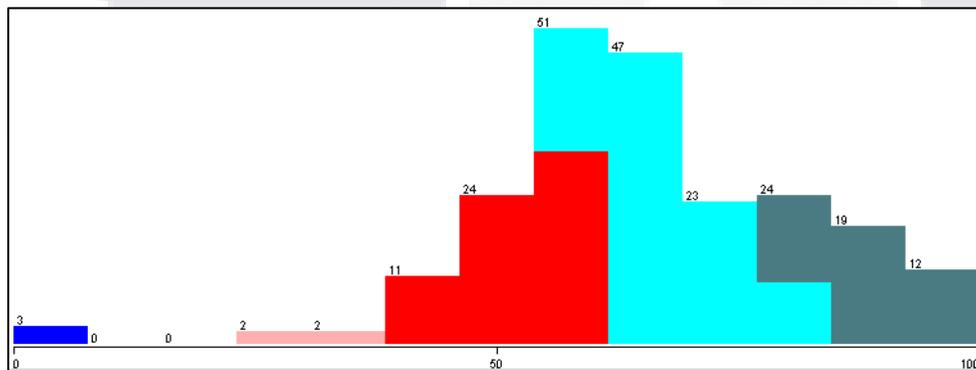


Figura 101 Histograma del participante normovisual 1 (AI).

Tabla 35 Datos del participante normovisual 1 (AI).

ID	N1
Sexo	Mujer
Tipo de Actividad	<i>Aprendizaje Explícito Monedas</i>
Atención promedio	65.606

Participante 2

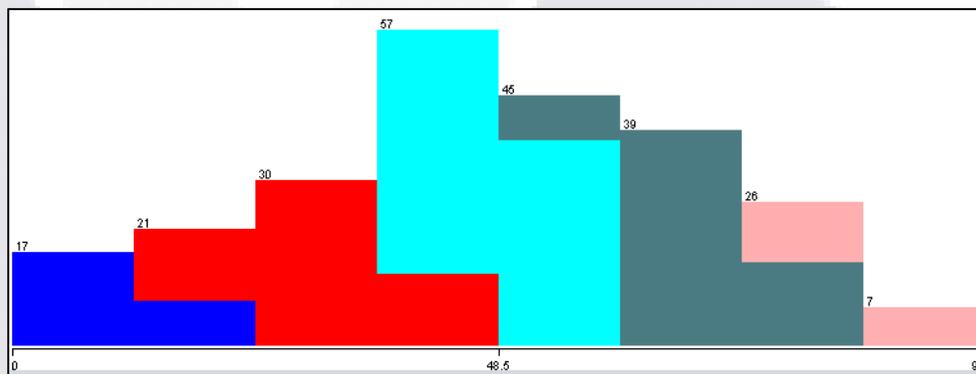


Figura 102 Histograma del participante normovisual 2 (AE).

Tabla 36 Datos del participante normovisual 2 (AE).

ID	N2
Sexo	Mujer
Tipo de Actividad	<i>Aprendizaje Implícito Canción</i>
Atención promedio	47.434

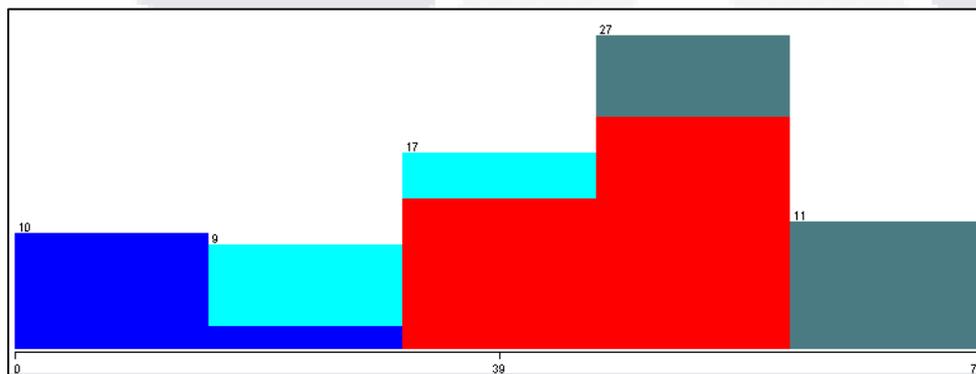


Figura 103 Histograma del participante normovisual 2 (AI).

Tabla 37 Datos del participante normovisual 2 (AI).

ID	N2
Sexo	Mujer
Tipo de Actividad	<i>Aprendizaje Explícito Monedas</i>
Atención promedio	42.514

8.1.10 Conclusiones.

En 3 de los 5 participantes ciegos, los niveles de atención fueron mayores en la tarea de aprendizaje implícito (La canción infantil sobre las partes del cuerpo en inglés), alcanzando valores topes en 56.795 y un valor mínimo realmente muy bajo en 25.588.

En cuanto a las dos participantes normovisuales, la primera de ellas mostró mayor atención en la tarea de aprendizaje explícito (juego de “Las 12 monedas”), pero por una diferencia muy pequeña con respecto a la implícita; mientras que para la participante 2, se observa mayor atención en la tarea de aprendizaje implícito, por una diferencia un poco mayor, pero no mayor a 5 puntos.

En general, al tomar en cuenta a los 7 participantes (5 ciegos y dos normovisuales), 4 de ellos mostraron valores de atención más altos en la tarea de aprendizaje Implícito que en la de aprendizaje explícito, probablemente, causado por el interés en la actividad.

8.2 Experimento 2: Análisis mediante Selección de atributos con CfsSubEval de WEKA.

8.2.1 Contexto de la experimentación.

Esta experimentación se llevó a cabo con un proceso muy parecido al utilizado en el Estudio Actual descrito a lo largo de la tesis, de hecho, sirvió de preámbulo para hacer las pruebas de adquisición con *OpenViBE* y el trabajo con *WEKA*.

En lugar de utilizar cuatro videos diferentes a selección del participante, únicamente se optó por el primero “¿Cómo funciona el cerebro?” (Anexo A). y únicamente se aplicó con cuatro participantes normovisuales (3 hombres y una mujer).

8.2.2 Aplicación de experimento.

Para realizar la experimentación:

- Se cita a los participantes en un cuarto o aula en solitario.

- TESIS TESIS TESIS TESIS TESIS
- Se les dan las instrucciones de la experimentación y se les pide que firmen la carta de consentimiento de participación.
 - Se les pide que estén relajados, en una postura cómoda y que presten atención al video que está por proyectarse frente a ellos.
 - Una vez finalizado el video, se les muestra el cuestionario y se les pide que lo respondan de manera breve.

Se ha realizado el experimento en 4 participantes normovisuales:

- Mujer, 50 años
 - Hombre, 20 años
 - Hombre, 23 años
 - Hombre, 24 años
- A continuación, se procede a eliminar los atributos de Tiempo y Época (puesto que estos mismos por sí solos no explican el comportamiento de las señales) y se normalizan los atributos restantes mediante el filtro “*Normalize*” (para evitar la gran variación de amplitud de los datos) de la pestaña de preprocesamiento del “*Explorer*”.
- Posteriormente, en un análisis de relación de atributos, en la pestaña “*Select Attributes*”, se fija “Atención” como clase y se ejecuta el atributo evaluador “*CfsSubSetEval*” con un Algoritmo de búsqueda “*BestFirst*” (Primero el mejor).

Nota:

CfsSubSetEval: Evalúa el valor de un subconjunto de atributos considerando la capacidad de predicción individual de cada característica junto con el grado de redundancia entre ellos.

8.2.3 Resultados con *CfsSubSetEval*

En esta sección, se muestran los resultados del análisis preliminar realizado con *WEKA*.

Tabla 38 Resultados de la aplicación *CfsSubSetEval*.

Participante 1: Mujer, 50 años		Participante 2: Hombre, 21 años	
Meditación		Meditación	
Beta Alta		Beta Alta	
Participante 3: Hombre, 23 años		Participante 4: Hombre, 24 años	
Meditación		Theta	
Beta Alta		Alfa Baja	Alfa Alta

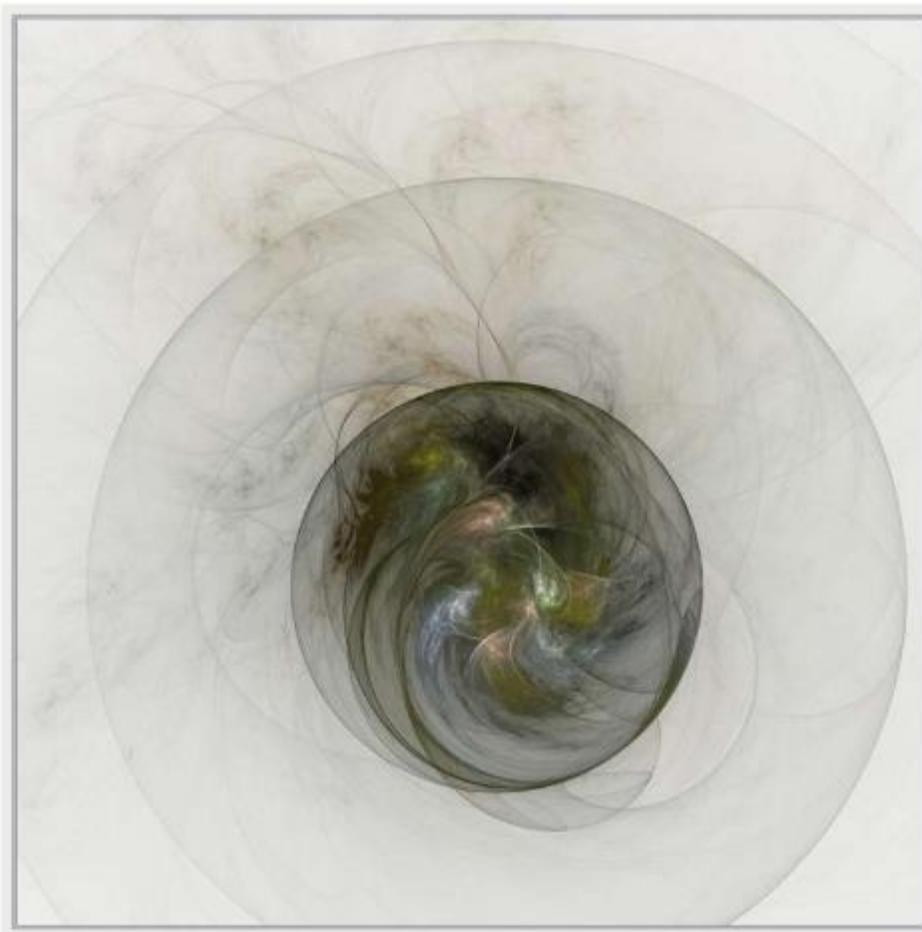
Discusiones y Conclusiones.

Mediante la aplicación de *CfsSubSetEval*, se encontró que, para tres de los cuatro participantes, las ondas cerebrales más ligadas a la clase “Atención”, fueron las mismas. Para los Participantes 1, 2 y 3, a pesar de las diferencias en edad y sexo, Meditación y Beta Alta son las que explican mejor el comportamiento de la clase.

Sin embargo, para el Participante 4, ninguna de las dos ondas anteriores tiene relación con su clase “Atención”. Así pues, las ondas que el presenta son Theta, Alfa Baja y Alfa Alta, consideradas de frecuencias lentas (Theta, de 4-7HZ) y Alfa (7-13Hz) lo que puede indicar falta de concentración, puesto que esta suele estar ligada comúnmente a frecuencias más altas.

Anexo I. Publicación en CONTIE 2018.

**AVANCES SOBRE REFLEXIONES,
APLICACIONES Y TECNOLOGÍAS
INCLUSIVAS**



ISBN: 978-607-97086-4-1

Proceso de medición de aprendizaje explícito (área lógica-matemática) aplicado en usuarios ciegos

Ana Guadalupe Rosales Zúñiga¹, Kevin Borja Díaz², Marbely Olivia German Beltrán³, Eduardo Emmanuel Rodríguez López⁴, Francisco Javier Álvarez Rodríguez⁵, Teresita de Jesús Álvarez Robles⁶

¹ TECN/ITP – Ingeniería Industrial, maygu2427@gmail.com
Felipe Ángeles Km. 84.5, Venta Prieta, 42083 Pachuca de Soto, Hgo. México

² UABC – Bioingeniería, kevin.borja@uabc.edu.mx
Avenida Álvaro Obregón s/n, Segunda, 21100 Mexicali, B.C., México

³ UABC – Bioingeniería, marbely.german@uabc.edu.mx
Avenida Álvaro Obregón s/n, Segunda, 21100 Mexicali, B.C., México

⁴ UAA – Maestría en Ciencias con Opción a Computación, Matemáticas Aplicadas, edwral@hotmail.com
Av. Universidad #940, 20130 Aguascalientes, Ags. México

⁵ UAA – Profesor Investigador, Departamento de Ciencias de la Computación, fjalvar.uaa@gmail.com
Av. Universidad #940, 20130 Aguascalientes, Ags. México

⁶ Facultad de Estadística e Informática, alvarez88.t@gmail.com
Av. Xalapa esq. Manuel Ávila Camacho s/n, col. Obrero Campesina, 91020. Xalapa, Veracruz, México.

Abstract. In this work, experimentation was developed to measure attention levels and alpha-beta rhythms during the performance of a mathematical logical reasoning task, a turn-based game called "the Twelve Coins". There is an evaluator who knows an infallible technique to win as long as he is the second player in turn. The electroencephalographic waves are measured during the game, applying the technique against the user, and then the game is repeated explaining the technique and inviting him to put it into practice. With this process, explicit learning is generated in the user, which is interpreted through the waves described above.

1 Introducción

Las matemáticas son parte de las ciencias deductivas que contribuyen a la agilización del razonamiento [1].

Una forma común de entrenar el razonamiento lógico – matemático es realizando test o exámenes de matemáticas, como los realizados durante la preparación académica, sin embargo, esta clase de pruebas suelen generar estrés y ansiedad al realizarse a gran cantidad de estudiantes universitarios [2], por lo cual, una forma alternativa con el mismo fin, son los juegos de razonamiento matemático, que no suponen una responsabilidad mayor al usuario que los realiza e incluso son divertidos y generan competitividad.

Los conocimientos que se busca que sean adquiridos conscientemente son conocidos como aprendizaje explícito, es decir, la persona que está aprendiendo, es totalmente consciente de ello, a diferencia del aprendizaje implícito, en el cual, las personas son inconscientes de su aprendizaje (como un niño que está aprendiendo a hablar).

Existen estudios de electroencefalografía (EEG) en los que se pueden medir ciertos patrones de las ondas cerebrales relacionados con la forma, frecuencia, amplitud o presencia o ausencia de ondas específicas.

Los electroencefalogramas suelen usarse en la práctica médica como apoyo en el diagnóstico de ciertas enfermedades o trastornos mentales. Sin embargo, en años recientes, se han desarrollado dispositivos capaces de adquirir las señales cerebrales con otro tipo de fines, como educativos o computacionales, son los llamados BCI, interfaces Cerebro-Computadora, que establecen una conexión de las ondas cerebrales con un sistema computacional. Para estos sistemas, hay aplicaciones que van desde los juegos hasta las de análisis científicos para investigación. Los BCI's comunes, permiten la adquisición de las ondas electroencefalográficas (Delta, Theta, Alfa, Beta y Gamma) y otro tipo de señales como la atención, meditación, estrés o parpadeo.

Gracias a estos dispositivos y a la gran variedad de software que hay para utilizarlos, se ha podido incrementar la investigación en ramas neurológicas – computacionales de bajo costo, sin la necesidad de sistemas de adquisición y procesamiento más complejos.

Así pues, mediante el análisis de las señales obtenidas con estos BCI's, pueden buscarse los patrones descritos con anterioridad que están relacionados con el aprendizaje y la memoria (métricas) bajo situaciones

Anexo J. Publicación pendiente en CONTIE 2019.




CONTIE 2019 • LACLO México 2019

II International Conference of Inclusive Technology and Education

Presents this certificate to

*Ana María Morales Vidal, Carolina López Justo, Eduardo Rodríguez ,
Francisco Javier Álvarez Rodríguez*

As authors of the paper titled:

*Comparación de Niveles de Atención entre personas Ciegas y
Normovisuales en un entorno de Aprendizaje mediante Análisis de
EEG.*

Presented at the

II International Conference of Inclusive Technology and Education
*Held in Los Cabos, Baja California Sur, México, on October 30, 31 and November 1st,
2019*



J. Andrés Sandoval Bringas
General Chair CONTIE 2019

November, 2019.
Los Cabos, Baja California Sur, México.



ritie
RED INTERNACIONAL
DE TECNOLOGÍAS
INCLUSIVAS Y
DE EDUCACION



ritie.org

Comparison of Levels of Attention between Blind and Normovisual People in a Learning Environment through EEG Analysis

Ana Morales
Ingeniería Mecatrónica
Instituto Tecnológico de
Cuatla, TecNM
Morelos, México
anama.mora@gmail.com

Carolina López
Facultad de Medicina
Universidad Autónoma del
Estado de México
Estado de México, México
clopezj234@alumno.uaemex.mx

Eduardo Rodríguez
Depto. De Ciencias de la
Computación
Universidad Autónoma de
Aguascalientes
Aguascalientes, México
edvral@hotmail.com

Francisco Álvarez
Depto. De Ciencias de la
Computación
Universidad Autónoma
de Aguascalientes
Aguascalientes, México
fjalvar.uaa@gmail.com

Abstract— In the present work, a comparison of the "Levels of Attention" was made between a group of blind people and another of normovisuals based on EEG records during the reproduction of a video of scientific divulgation and a questionnaire related to the video as a learning environment. The data was acquired by the MindWave Mobile device, while the analysis of the data was made in Weka, using "InfoGain", a tool which evaluated the attribute by measuring the information gain with respect to the class. The class consists of a classification of attention: "Very good", "Good", "Fair", "Bad" and "Very bad", based on the percentages activated by the attribute "Attention". The results indicated in both groups obtained a similar average of attention in a range of "Good" to "Bad". While through the application of InfoGain it was obtained that the waves with the greatest weight in the classification "Level of Attention" were: Delta, Theta, Attention and Low Alpha in both groups. In addition to High Beta specifically in the group of normovisuals.

Keywords— EEG, Attention, Learning, Blind, Information Gain,

I. INTRODUCCIÓN

l electroencefalograma (EEG) se ha convertido en una herramienta fundamental en el análisis del comportamiento del cerebro [1], logrando asociar ciertas conductas cognitivas a zonas y/u ondas cerebrales específicas. Una de las conductas de mayor interés es el aprendizaje, es por ello, que se han desarrollado algoritmos capaces de medir el nivel de atención de las personas. Puesto que se ha demostrado que las señales de EEG contienen información considerable para el reconocimiento de la atención y ofrecen soluciones efectivas y objetivas para detectar la atención en el proceso de aprendizaje [2], logrando un impacto significativo en disciplinas como psicología, pedagogía, neurociencias e ingeniería, alcanzando procesos de aprendizaje más eficientes, aplicaciones en rehabilitación o el desarrollo de sistemas cerebro-computadora.

La atención como se mencionó antes es un estado de ánimo presente durante tareas de aprendizaje, que se ha logrado

medir a través del uso de registros de EEG y clasificar ciertas ondas con frecuencias específicas a tareas concretas [3]. Aunque la mayoría de los registros se ha llevado a cabo en personas normovisuales, se sabe que en personas ciegas el comportamiento del cerebro tiende a ser diferente, la corteza occipital asociada a tareas visuales en ciegos desarrolla otras funciones [4]. Por lo que la actividad cerebral durante tareas de aprendizaje está más enfocada a activar áreas auditivas, sensoriales y motoras. No obstante, el uso de EEG en el estudio del aprendizaje de personas ciegas no ha tenido gran desarrollo, presentando un mayor enfoque en el estudio de tareas de ubicación[5].

Por otro lado, el aumento del interés por comprender el comportamiento del cerebro ha llevado al desarrollo de sistemas de adquisición de datos cada vez un proceso más sencillo, es decir, el uso de un menor número de electrodos y métodos menos invasivos para obtener registros de la actividad cerebral. Estos sistemas tienen la ventaja de ser portátiles y accesibles económicamente, lo que ha ayudado a un crecimiento en el desarrollo de interfaces cerebro-computadora [6].

El dispositivo NeuroSky MindWave Mobile utiliza este tipo de tecnología. Además de que ya ha sido utilizado para la evaluación de la atención en procesos de aprendizaje [6][7][8][9]. Posicionándose como una alternativa de bajo costo para la adquisición de señales de la actividad cerebral que puedan ser procesadas para aplicaciones de reconocimiento de patrones y procesamiento digital de señales [6]. Este dispositivo cuenta con un sensor pasivo EEG seco y tecnología Bluetooth para transferir la información.

En este trabajo se pretende utilizar la diadema NeuroSky MindWave Mobile para comparar la actividad cerebral entre personas normovisuales y ciegas, esperando que los registros obtenidos sean de utilidad en el desarrollo de tecnologías de educación, asistencia y rehabilitación para personas ciegas, puesto que todavía existe la necesidad de crear métodos

Anexo K. Cartel publicado en CIIP UAA 2019.

 <p>UNIVERSIDAD AUTÓNOMA DE AGUASCALIENTES</p>	 <p>10° CONGRESO INTERNACIONAL LA INVESTIGACIÓN EN EL POSGRADO</p>
<p>EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ UNIVERSIDAD AUTÓNOMA DE AGUASCALIENTES PRESENTE</p>	
<p>Estimado(a) EDUARDO EMMANUEL RODRÍGUEZ LÓPEZ</p>	
<p>Por este medio me permito informarle que su trabajo titulado “ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUEDA DE PATRONES DE APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES.” fue ACEPTADO para participar en la modalidad CARTEL dentro del 10°. Congreso Internacional “La Investigación en el Posgrado” en la Mesa 3: Ciencias Exactas e Ingenierías, que tendrá lugar los días 2, 3, y 4 de octubre del presente año en la Unidad de Estudios Avanzados de la Universidad Autónoma de Aguascalientes.</p>	
<p>Los trabajos en la modalidad cartel, deberán colocarse en el mezanine de la Unidad de Estudios Avanzados de acuerdo al orden y hora asignados en el Programa Específico que se publicará en la página del Congreso, se recomienda portar diurex o algún otro material para la colocación de su cartel.</p>	
<p>Le solicitamos confirmar su participación en el Congreso antes del 23 de agosto en el apartado de Depósito del sistema en línea, esto para efectos de logística y elaboración de material. Aquellas personas que no confirmen su participación no serán consideradas en el programa del evento, ni se generará la constancia de participación correspondiente.</p>	
<p>El programa específico se podrá consultar en la página del Congreso a partir del 13 de septiembre del presente año.</p>	
<p>Le informamos que se ofrecerán talleres para su formación profesional sin costo y con cupo limitado, por lo que le sugerimos estar al pendiente en la página del congreso para realizar el registro.</p>	
<p>La información del programa académico, de los talleres a ofertar, así como de las actividades académicas y culturales, se podrá consultar en el siguiente enlace: http://posgrados.dgip.uaa.mx/congreso/ciip-2019/</p>	

ANÁLISIS DE SEÑALES EEG PARA LA BÚSQUDA DE PATRONES DE APRENDIZAJE DE PERSONAS CON CEGUERA Y NORMOVISUALES.

Por: Ing. Eduardo Emmanuel Rodríguez López
 Maestría en Ciencias de la Computación, Matemáticas Aplicadas, UAA
 4to semestre.
 Tutor: Dr. Francisco Javier Álvarez Rodríguez
 Cotutor: Dr. Miguel Vargas Martín
 Asesores: Dr. Julio Cesar Ponce gallegos, Dr. LUIS Daniel Cuéllar Garrido



•INTRODUCCIÓN: Hoy en día, los avances en los estudios de electroencefalografía permiten identificar y generar nuevo conocimiento sobre cómo los humanos pensamos desde un análisis sustentado en la fisiología. Un electroencefalograma (EEG) es el registro, mediante electrodos en el cuero cabelludo, de las corrientes eléctricas ocasionadas por los potenciales sinápticos producidos en los cuerpos celulares y las dendritas de la corteza cerebral [1]. Los electroencefalogramas facilitan y apoyan en el estudio de muchas áreas del conocimiento, no solo la medicina. Por ejemplo, la psicología, en la cual los EEG han facilitado desde la aplicación de pruebas psicológicas hasta la evaluación de la activación de determinadas regiones cerebrales para estudios de cognición [2]. En el presente trabajo, se expone el análisis de señales EEG para la identificación de patrones o características de aprendizaje (atención y meditación principalmente) mediante técnicas y algoritmos de Machine Learning (Aprendizaje Automático) para dos grupos de personas distintas: ciegos y normovisuales. Por el momento, los avances en la experimentación solo contemplan personas normovisuales.

•OBJETIVO: Identificar las principales características asociadas a la concentración y la meditación en usuarios con ceguera y normovisuales presentes en los registros electroencefalográficos mediante Machine Learning durante la realización de actividades de aprendizaje y memoria.

•METODOLOGÍA: Se registran las señales EEG de los participantes mientras ven un video educativo sobre el funcionamiento del cerebro y realizan un breve cuestionario sobre este mismo. Posteriormente las señales EEG son filtradas y procesadas mediante software para analizarlas finalmente con algoritmos de Machine Learning.

RESULTADOS: Hasta el momento de la experimentación, se han realizado pruebas con cuatro participantes normovisuales, encontrando que las señales que más impacto tienen en la atención son (Tabla 1): * Mujer, 50 años: Meditación, Beta Alta * Hombre, 21 años: Meditación, Beta Alta * Hombre, 23 años: Meditación, Beta Alta * Hombre, 24 años: Theta, Alfa Baja, Alfa Alta

Tabla 1. Impacto de las señales en los participantes.

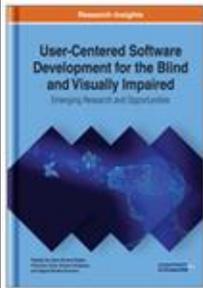
Participante 1: Mujer, 50 años • Meditación • Beta Alta	Participante 2: Hombre, 21 años • Meditación • Beta Alta
Participante 3: Hombre, 23 años • Meditación • Beta Alta	Participante 4: Hombre, 24 años • Theta • Alfa Baja • Alfa Alta

Participante 1: Mujer, 50 años • Mid Gamma (Power Spectrum) • Delta Signal • Alpha Signal • Gamma Signal	Participante 2: Hombre, 21 años • Delta (Power Spectrum) • Delta Signal • Alpha Signal • Gamma Signal
Participante 3: Hombre, 23 años • Theta (Power Spectrum) • Delta Signal • Alpha Signal • Gamma Signal	Participante 4: Hombre, 24 años • Theta (Power Spectrum) • Delta Signal • Alpha Signal • Gamma Signal

CONCLUSIÓN: Con los resultados obtenidos hasta el momento, resalta que para tres de los cuatro participantes normovisuales, las señales que más impacto tienen en la atención son las mismas: Meditación y Beta Alta, mientras que para el último participante, son totalmente distintas, lo que sugiere que la atención durante la experimentación fue muy poca o no enfocada a la actividad de aprendizaje.

BIBLIOGRAFÍA: [1] S. I. Fox, Fisiología humana (13a. ed.). McGraw Hill Mexico, 2014. [2] V. M. A. Romero and E. G. Díaz, Texto de neurociencias cognitivas. El Manual Moderno, 2001

Anexo L. Capítulo en libro *User-Centered Software Development for the Blind and Visually Impaired: Emerging Research and Opportunities*.



Hedonic Utility Scale (HED/UT) Modified as a User Experience Evaluation Method of Performing Talkback Tutorial for Blind People

Eduardo Emmanuel Rodríguez López (Universidad Autónoma de Aguascalientes, Mexico), Jean Sandro Chery (Instituto Tecnológico de Morelia, Mexico), Teresita de Jesús Álvarez Robles (Universidad Veracruzana, Mexico) and Francisco Javier Álvarez Rodríguez (Universidad Autónoma de Aguascalientes, Mexico)

Source Title: [User-Centered Software Development for the Blind and Visually Impaired: Emerging Research and Opportunities](#)

Copyright: © 2020 | Pages: 16

DOI: 10.4018/978-1-5225-8539-8.ch005

Abstract

Hedonic utility scale is a user experience (UX) evaluation method that, through a questionnaire, collects the hedonic and utilitarian dimensions of a product by rating items belonging to each dimension. In this chapter, it is proposed to adapt this method for its application with blind users using the Google TalkBack tutorial as a case study. Based on Nielsen's heuristics, five blind users rated the tutorial after completing each of its five tasks. To ensure inclusiveness in the adaptation of the method, this could be answered verbally and with the use of cards written in Braille, while, for questions of practicality in the evaluation, the number of items was reduced as well as changed the way of scoring (scale and equations) with respect to the original HED/UT. The scale of grades was ranked from 1 (very little) to 5 (quite), getting TalkBack scores between 4 and 5. The results show that the TalkBack tutorial is generally well accepted and well rated by users in both dimensions (hedonic and utility).

Chapter Preview

Top

Introduction

In 2010, according to data from the World Health Organization, the estimated number of visually impaired people worldwide was close to 285 million, of whom 39 million were blind (OMS, 2017). In Latin America, 1 – 4% of population is blind (IAPB, 2014). Meanwhile in Mexico, according to figures from the same year, there were 1,292,201 people in the country with a limitation in activities to visualize, according to INEGI (INEGI).

The technological world is advancing by leaps and bounds, and human-computer interaction (HCI), "a multidisciplinary research area focused on interaction modalities between humans and computers" (Paolo Montuschi, 2014) is involved in everything humans do in everyday life. Although this progress is not entirely inclusive, since millions of applications are developed with any objective, from covering communication needs, to leisure or fun, without considering in equal measure, applications that can facilitate the lives of people with disabilities. This inequality can generate a digital divide, between people with access to all content (called info rich people) and people without access (called info poor people) (Villatoro & Silva, 2005). It is important to point out that as Cabero - Almenara says, "the separation of communication technologies is becoming a reason for social exclusion and separation" (Cabero-Almenara, 2008) therefore, actions must be taken to help minimize the digital divide (it should be clarified that there are several types of digital divide, such as access gap, gender gap, etc.).

Chapter 5 Hedonic Utility Scale (HED/UT) Modified as a User Experience Evaluation Method of Performing Talkback Tutorial for Blind People

Eduardo Emmanuel Rodríguez López
*Universidad Autónoma de
Aguascalientes, Mexico*

Jean Sandro Chery
*Instituto Tecnológico de Morelia,
Mexico*

Teresita de Jesús Álvarez Robles
Universidad Veracruzana, Mexico

Francisco Javier Álvarez Rodríguez
 <https://orcid.org/0000-0001-6608-046X>
*Universidad Autónoma de
Aguascalientes, Mexico*

ABSTRACT

Hedonic utility scale is a user experience (UX) evaluation method that, through a questionnaire, collects the hedonic and utilitarian dimensions of a product by rating items belonging to each dimension. In this chapter, it is proposed to adapt this method for its application with blind users using the Google TalkBack tutorial as a case study. Based on Nielsen's heuristics, five blind users rated the tutorial after completing each of its five tasks. To ensure inclusiveness in the adaptation of the method, this could be answered verbally and with the use of cards written in Braille, while, for questions of practicality in the evaluation, the number of items was reduced as well as changed the way of scoring (scale and equations) with respect to the original HED/UT. The scale of grades was ranked from 1 (very little) to 5 (quite), getting TalkBack scores between 4 and 5. The results show that the TalkBack tutorial is generally well accepted and well rated by users in both dimensions (hedonic and utility).

DOI: 10.4018/978-1-5225-8539-8.ch005

Copyright © 2020, IGI Global. Copying or distributing in print or electronic forms without written permission of IGI Global is prohibited.