
Megaproyecto Detección Automatizada del Engaño DAE



UNIVERSIDAD DEL VALLE DE GUATEMALA
Facultad de Ingeniería



**Megaproyecto Detección Automatizada del Engaño
DAE**

Trabajo de graduación en modalidad de megaproyecto presentado por:

Pablo Andrés Barreno Koch,
Rodrigo José Castro Godínez,
Bryan Rougeil Chan González,
Olga Lucía Cobaquil Barahona,
Rudy Alexandro Garrido Veliz,
Leonel Guillén del Valle,
Hugo Rafael Noriega Chum y
Álvaro Roberto Sánchez Tórtola

para optar por el grado académico de Licenciados en Ingeniería en Ciencia de la
Computación y Tecnologías de la Información;

Andrea Castañeda Chavaría y
Javier Andrés Zarazúa Rosales

para optar por el grado académico de Licenciados en Psicología.

Guatemala
2018

UNIVERSIDAD DEL VALLE DE GUATEMALA
Facultad de Ingeniería



**Megaproyecto Detección Automatizada del Engaño
DAE**

Trabajo de graduación en modalidad de megaproyecto presentado por:

Pablo Andrés Barreno Koch,
Rodrigo José Castro Godínez,
Bryan Rougeil Chan González,
Olga Lucía Cobaquil Barahona,
Rudy Alexandro Garrido Veliz,
Leonel Guillén del Valle,
Hugo Rafael Noriega Chum y
Álvaro Roberto Sánchez Tórtola

para optar por el grado académico de Licenciados en Ingeniería en Ciencia de la
Computación y Tecnologías de la Información;

Andrea Castañeda Chavaría y
Javier Andrés Zarazúa Rosales

para optar por el grado académico de Licenciados en Psicología.


Guatemala
2018

Vo.Bo.:

(f) 
MSc. Douglas Leonel Barrios Gonzalez

Tribunal Examinador:

(f) 
MSc. Douglas Leonel Barrios Gonzalez

(f) 
PhD Pablo Eduardo Barrientos

(f) 
Ing. Lynette García Pérez

Fecha de aprobación: Guatemala, 20 de noviembre de 2018

La elaboración del presente megaproyecto surgió del interés del Departamento de Computación y Tecnología de la Información en explorar la efectividad de un sistema de detección del engaño a partir de la toma de tres diferentes medidas de manifestaciones de engaño. Siendo una investigación de tipo exploratorio, se delimitó a determinar los factores que influyen en la elaboración de engaño y desarrollar un sistema que aproxime una probabilidad de engaño en los sujetos entrevistados. Ambas tareas representan un reto para los especialistas en la detección del engaño. Al formar el equipo de investigación era importante contar con estudiantes capacitados en computación y tecnología, como también con estudiantes capacitados en el comportamiento humano. También fue necesario consultar con profesionales expertos otras áreas, como lo es la estadística. El trabajo interdisciplinario fue fundamental para realizar una simulación de engaño, recabar datos e implementar las herramientas propuestas.

Prefacio	III
Lista de figuras	IX
Lista de cuadros	XI
Resumen	XII
1. Introducción	1
2. Objetivos	2
2.1. Objetivo general	2
2.2. Objetivos específicos	2
3. Justificación	4
4. Marco teórico	5
4.1. Engaño	5
4.2. Procesos cognitivos en el engaño	6
4.3. Personalidad	7
4.3.1. Psicopatía	7
4.4. Procesos emotivos	8
4.5. Las expresiones faciales y las emociones	8
4.6. Inteligencia Emocional	10
4.6.1. Modelo mixto	10
4.6.2. Modelo de habilidad	10
4.6.3. Modelo de Salovey y Mayer	10
4.7. Creencias sobre el engaño	11
4.8. El engaño y el rostro	12
4.9. Neurología de la psicopatía e inteligencia emocional	15
4.10. Sonido	15
4.10.1. Almacenamiento - WAV	15
4.11. SoX - Sound eXchange	16
4.11.1. Decibel	16
4.11.2. Factor de cresta	16
4.12. Electroencefalografía	16
4.13. Emotiv	17

4.14. Aprendizaje estadístico	17
4.15. Métodos no-paramétricos	19
4.16. Transformada de Fourier	19
4.17. Inteligencia artificial	20
4.18. Aprendizaje supervisado	20
4.18.1. Clustering	21
4.18.2. Método del codo	21
4.18.3. Árbol de decisión	21
4.19. Minería de texto	21
4.19.1. Nube de palabras	22
4.19.2. N-gramas	22
4.20. Máquinas de soporte vectorial (SVM)	22
4.20.1. Kernels	24
4.21. Redes neuronales	25
4.22. Redes neuronales convoluciones	26
4.23. K vecinos más cercanos	26
4.24. KNIME	27
4.25. Python	27
4.26. MongoDB	28
4.27. Flask	28
4.28. VueJS	28
4.29. Socket.IO	28
4.30. pyAudio	28
4.31. OpenCV	28
4.32. Scikit-learn	28
4.33. Dlib	29
5. Antecedentes	30
5.1. Estudio de detección del engaño	30
5.2. Relación entre psicopatía e inteligencia emocional	31
5.3. PCL-R en otras poblaciones	31
5.4. Detección de microexpresiones	31
5.5. Uso de emotiv	32
5.6. Tiempos de reacción	33
6. Alcance	34
7. Marco metodológico	35
7.1. Recopilación de datos	35
7.1.1. Convocatoria y formulario sociodemográfico	35
7.1.2. Entrevistas	35
7.1.3. Pruebas psicométricas	36
7.2. Población y muestra	36
7.3. Análisis estadísticos	37
7.4. Detección de parpadeos y posición de los ojos	37
7.5. Preparación de datos	38
7.5.1. Voz	38
7.5.2. Transformada de Fourier	39
7.5.3. Señales electroencefalográficas	40
7.5.4. Microexpresiones	40
7.5.5. Procesamiento de videos	40
7.6. Selección variables	41
7.6.1. Voz con redes neuronales probabilísticas	41
7.6.2. Voz con k vecinos más cercanos	41

7.6.3.	Electroencefalografía	41
7.6.4.	Puntos de referencia facial	42
7.7.	N-gramas	42
7.8.	Implementación de modelos	42
7.8.1.	Voz con redes neuronales probabilísticas	42
7.8.2.	Voz con k vecinos más cercanos	43
7.8.3.	KNN con señales electroencefalográficas	43
7.8.4.	Redes neuronales con señales electroencefalográficas	44
7.8.5.	SVM con señales electroencefalográficas	44
7.8.6.	Redes neuronales convolucionales con imágenes de rostros	44
7.8.7.	Máquinas de soporte de vectores con distancias de puntos de referencia facial	45
7.9.	Implementación de aplicación unificada	45
7.10.	Pruebas finales	45
8.	Resultados	46
8.1.	Análisis exploratorio	46
8.2.	Correlaciones con microexpresiones	47
8.2.1.	Con memoria de trabajo	47
8.2.2.	Con velocidad de procesamiento	47
8.2.3.	Con índice global de inteligencia emocional	47
8.2.4.	Con índices de habilidad de inteligencia emocional	48
8.2.5.	Con psicopatía	50
8.3.	MANOVAS de medidas repetidas para tiempo de reacción y tiempo de demora	50
8.3.1.	Con memoria de trabajo	50
8.3.2.	Con velocidad de procesamiento	50
8.3.3.	Con índice global de inteligencia emocional	51
8.3.4.	Con índices de habilidad de inteligencia emocional	52
8.3.5.	Con psicopatía	57
8.4.	Correlaciones con datos de electrodos	58
8.4.1.	Con memoria de trabajo	58
8.4.2.	Con velocidad de procesamiento	58
8.4.3.	Con Índice Global de Inteligencia Emocional	58
8.4.4.	Con Índices de Habilidad de Inteligencia Emocional	59
8.4.5.	Con psicopatía	60
8.5.	Voz con redes neuronales probabilísticas	60
8.6.	Voz con k vecinos más cercanos	62
8.7.	N-gramas	65
8.8.	Señales electroencefalográficas con KNN	68
8.9.	Señales electroencefalográficas con redes neuronales	71
8.10.	Señales electroencefalográficas con SVM	71
8.11.	Entrenamiento con máquinas de soporte de vectores con distancias	74
8.12.	Entrenamiento con imágenes en red neuronal convolucional	75
8.13.	Entrenamiento con características de los ojos en una red neuronal y máquinas de vectores de soporte	76
8.14.	Patrones de comportamiento de los ojos	76
8.15.	Aplicación unificada	78
9.	Discusión	79
10.	Conclusiones	85
11.	Recomendaciones	88
12.	Bibliografía	90
Referencias		90

13. Anexos	93
A. Entrevistas	94
B. Script de extracción de estadísticas utilizando SoX, Voz PNN	96
C. Estructura de MongoDB — Ejemplo, Voz PNN	97
D. Estructura de base de datos en Mysql para el módulo de señales de electroencefalografía	98
E. Capturas de pantalla de herramienta	99
14. Glosario	102
Lista de Símbolos	103

Lista de figuras

4.1. Gráfica de respuestas de la primera encuesta	11
4.2. Gráfica de respuestas de la primera encuesta	11
17figure.caption.62	
18figure.caption.64	
4.5. Transformada de Fourier.	20
23figure.caption.83	
4.7. Cálculo de la distancia euclidiana	27
4.8. Cálculo de la distancia manhattan	27
7.1. diagrama de puntos detectores de intensidad de pixeles	38
7.2. Gráfica de señal de audio.	39
7.3. Gráfica de audio en dominio de frecuencia.	40
8.1. Método codo.	46
8.2. Gráfica descriptiva de MANOVAS de Tiempo de Duración para SDMT	51
8.3. Gráfica descriptiva de MANOVAS de Tiempo de Duración para CIE	52
8.4. Gráfica descriptiva de MANOVAS de Tiempo de Duración para Índice de Percepción Emocional	53
8.5. Gráfica descriptiva de MANOVAS de Tiempo de Reacción de Índice de Facilitación Emocional	54
8.6. Gráfica descriptiva de MANOVAS de Tiempo de Demora de Índice de Facilitación Emocional	55
8.7. Gráfica descriptiva de MANOVAS de Tiempo de Demora de Índice de Comprensión Emocional	56
8.8. Gráfica descriptiva de MANOVAS de Tiempo de Demora de Índice de Manejo Emocional	57
8.9. Gráfica descriptiva de MANOVAS de Tiempo de Demora de la Escala de Psicopatía	58
8.10. Matriz de correlación para las variables extraídas	61
8.11. Resultados para redes neuronales probabilísticas	61
8.12. Árbol de decisión para la elección de variables.	62
8.13. Matriz de correlación de los datos ingresados.	63
8.14. Matriz de confusión para k vecinos más cercanos.	65
8.15. Matriz de confusión para máquinas de vectores de s.	65
8.16. Matriz de confusión para bosques aleatorios.	65
8.17. Precisión de la Máquina de Vectores de Soporte con kernel RBF.	72
8.18. Precisión de la Máquina de Vectores de Soporte con kernel Lineal.	72
8.19. Precisión de la Máquina de Vectores de Soporte con kernel Polinomial.	73

8.20. Precisión de la Máquina de Vectores de Soporte con kernel RBF con distintos valores de C y γ	73
8.21. Rostro en escala de gris a una resolución de 48 por 48 pixeles	75
8.22. Rostro en escala de gris a una resolución de 96 por 96 pixeles	75
8.23. Frecuencias de posiciones de los ojos	76
8.24. Frecuencias de posiciones de los ojos separados por verdad y mentira	77
8.25. Diagrama de secuencia de la aplicación unificada utilizando los scripts de automatización para predicción	78
D.1. Diagrama entidad-relación para el almacenamiento de los datos de señales EEG	98
E.1. Sistema en espera, listo para iniciar una pregunta	99
E.2. Sistema grabando desde la cámara, micrófono y Emotiv.	100
E.3. Sistema procesando la información y ejecutando los algoritmos de aprendizaje de máquina de cada módulo	100
E.4. Sistema reportando los resultados de cada módulo	101

Lista de cuadros

8.1. Análisis exploratorio.	47
8.2. Correlaciones entre Microexpresiones de Comisuras de la boca y CIE	48
8.3. Correlaciones de Microexpresiones con Índice de Comprensión Emocional	49
8.4. Correlaciones de Microexpresiones con Índice de Manejo Emocional	49
8.5. Comparaciones múltiples por veracidad y nivel de SDMT para tiempos de duración .	50
8.6. Comparaciones múltiples por veracidad y nivel de CIE para tiempos de duración . .	51
8.7. Contrastes Multivariados de Índice de Percepción Emocional	52
8.8. Contrastes Multivariados de Índice de Facilitación Emocional	53
8.9. Contrastes Multivariados de Índice de Comprensión Emocional	55
8.10. Contrastes Multivariados de Índice de Manejo Emocional	56
8.11. Correlaciones entre CIE y Actividad electroencefalográfica en F4	59
8.12. Correlaciones entre Percepción Emocional y Actividad Electroencefalográfica	59
8.13. Correlaciones entre Facilitación Emocional y Actividad Electroencefalográfica	59
8.14. Correlaciones entre Comprensión Emocional y Actividad Electroencefalográfica	60
8.15. Correlaciones entre Manejo Emocional y Actividad Electroencefalográfica	60
8.16. Variables elegidas de la regresión logística.	62
8.17. Variables seleccionadas para el entrenamiento de algoritmos	63
8.18. Resultados de diferentes parámetros para algoritmo k vecinos más cercanos.	64
8.19. Resultados de diferentes parámetros para el algoritmo máquinas de vectores de soporte.	64
8.20. Resultados de diferentes parámetros para el algoritmo bosques aleatorios.	64
8.21. Mejor porcentaje de precisión para los algoritmos evaluados.	65
8.22. Frecuencia de palabras.	65
8.23. Bigramas verdad.	66
8.24. Bigramas mentira.	66
8.25. Trigramas verdad.	66
8.26. Trigramas mentira.	67
8.27. N-gramas verdad.	67
8.28. N-gramas mentira.	67
8.29. Precisión del modelo con KNN, en 10 corridas con $K = 15$	68
8.30. Precisión del modelo con KNN, en 10 corridas con $K = 17$	68
8.31. Precisión del modelo con KNN, en 10 corridas con $K = 19$ sin normalizar los datos .	68
8.32. Precisión del modelo con KNN, en 10 corridas con $K = 19$ con datos normalizados .	69
8.33. Precisión del modelo con KNN, en 10 corridas con $K = 19$, para conjunto de variables relevantes	69
8.34. Precisión del modelo con KNN, en 10 corridas con $K = 19$, excluyendo las variables relevantes	69
8.35. Validación cruzada	70

8.36. Resultados finales de pruebas con KNN	70
8.37. Variación de porcentaje de confiabilidad con la cantidad de capas: número de neuronas fijo de 10 por capa	71
8.38. Variación de porcentaje de confiabilidad con la cantidad de neuronas: número de capas fijo de 6	71
8.39. Porcentajes de confiabilidad de la red neuronal con diferentes funciones de activación	71

Con el objetivo de desarrollar una herramienta que combine diferentes metodologías para la detección del engaño, se realizó un sistema que combinara diferentes algoritmos de aprendizaje de máquina con la capacidad de clasificación de verdad o mentira. Para esto se dividió el tres módulos principales: señales electroencefalográficas, análisis de voz y análisis de microexpresiones.

El proyecto se desarrolló en cinco etapas. La primera consistió en la preparación de entrevistas a miembros de la comunidad de la Universidad del Valle de Guatemala, los cuales fueron atendidos en citas individuales que tenían como objetivo la recopilación de datos para cada uno de los módulos. Se les pasó un Consentimiento informado, se les pidió que llenaran un cuestionario socio-demográfico y se les hizo una entrevista estructurada que contenía una parte en la que se les pidió que contestaran con la verdad y otra con la mentira. De estas preguntas se obtuvieron los datos para el entrenamiento de los diferentes módulos. Posteriormente, se les aplicó una serie de pruebas de carácter psicométrico, con el objetivo de recopilar datos psicológicos de las personas. La segunda etapa consistió en la preparación de los datos para el entrenamiento, en donde cada módulo realizó el manejo pertinente para obtener datos utilizables para los algoritmos. En la tercera etapa, a partir del conjunto de datos obtenidos, cada integrante de los módulos realizó un análisis exploratorio de variables, y por medio de la interpretación de los resultados, se obtuvieron las variables que se utilizarían para el entrenamiento, las cuales variaron según las necesidades de cada implementación. La cuarta etapa consistió en el desarrollo e implementación de los algoritmos elegidos por los integrantes de cada módulo. Para cada uno, se definió como respuesta al ingreso de datos a evaluar, la clasificación de este input y el porcentaje de acierto de esta clasificación. Esta respuesta fue implementada en la herramienta final. La quinta etapa, consistió en la implementación de los ocho diferentes algoritmos realizados por los módulos, los cuales, por medio de una interfaz gráfica integradora, desplegaron al usuario la clasificación de verdad o mentira para cada ingreso de datos dado.

CAPÍTULO 1

Introducción

La detección del engaño es una tarea compleja, por lo que los especialistas necesitan de herramientas adecuadas para no dejar que sus emociones influyan en su juicio. Actualmente, existe insuficiente integración de las diferentes técnicas para la detección del engaño que le facilite al especialista la toma de decisiones. Muchas de las herramientas se basan en la detección de microexpresiones, reacciones fisiológicas y observaciones de conducta, que brindan información valiosa e indicios de engaño. Sin embargo, existe discrepancia entre los diferentes métodos y aún no ha sido desarrollado un sistema que integre estos. Por otro lado, no hay variedad de herramientas que tomen en cuenta el proceso por el cual el cerebro construye una mentira, ni el efecto que tienen las emociones en la cognición, para determinar qué indicadores cognitivos son más precisos para detectar la misma.

El Megaproyecto de Detección Automatizada del Engaño, de la Facultad de Ingeniería de la UVG, busca integrar varias de las herramientas de detección del engaño para generar un sistema de apoyo su detección. Esta investigación combina conocimientos del ámbito de Psicología y del ámbito de Ingeniería. Se presentan resultados de las manifestaciones de engaño a través de microexpresiones, señales de audio y señales electroencefalográficas.

El presente documento se ha organizado con el objetivo de brindar al lector una secuencia lógica para la comprensión del proyecto. Como primer punto importante se encuentra la sección de marco teórico, la cual contienen la información necesaria para comprender la razón de implementación de cada módulo y la tecnología necesaria para estos. Posteriormente se describe de forma detallada la metodología seguida para la implementación. Por último, los resultados para cada módulo y discusión de los mismos.

2.1. Objetivo general

Elaborar una herramienta automatizada que combina diferentes técnicas de modo que apoyen a un especialista en la detección del engaño.

2.2. Objetivos específicos

- Determinar el porcentaje de precisión del modelo de aprendizaje supervisado para predicción del engaño.
- Evaluar la eficacia de algoritmos de aprendizaje de máquina detectando la veracidad de ideas transmitidas por medio de la voz, utilizando cortos segmentos de audio.
- Determinar un conjunto de variables obtenidas de segmentos de audio relevantes relacionadas al engaño.
- Construir un módulo con una interfaz de programación bien definida para su reutilización.
- Analizar las lecturas provistas por un electroencefalograma para clasificar una respuesta como verdad o mentira para lo cual se desarrollará un programa que contenga un modelo para dicha clasificación.
- Identificar las variables más influyentes en la detección del engaño, a partir del conjunto de lectura de señales electroencefalográficas, pruebas psicometrías y perfil socio demográfico
- Procesar archivos de voz para la implementación en algoritmos de aprendizaje de máquina.
- Evaluar la eficiencia de algoritmos de aprendizaje de máquina para la detección del engaño por medio del análisis de voz.
- Detectar patrones en las variaciones del tono de voz, intensidad de la misma; y frecuencia de palabras, que influyan en la detección del engaño
- Diseñar una interfaz de usuario para el consumo de los servicios de detección del engaño que tenga la mayor eficiencia de predicción.

- Identificar patrones cognitivos y emotivos comunes involucrados en la construcción de una mentira, por medio de las señales electroencefalográficas y detección de microexpresiones.
- Determinar en qué medida la memoria de trabajo, la velocidad de procesamiento y el Índice de Inteligencia Emocional pueden predecir las manifestaciones de engaño.
- Explorar la relación entre las habilidades que componen la inteligencia emocional con las manifestaciones de engaño.
- Explorar la relación entre los resultados de la escala de psicopatía con las manifestaciones de engaño.
- Explorar qué índice de inteligencia emocional guarda mayor relación la psicopatía a partir de las manifestaciones de microexpresiones.
- Clasificar los datos obtenidos por el dispositivo *Emotiv Epoc* para ser procesados por el algoritmo de detección del engaño.
- Evaluar la efectividad de detección del engaño del programa basado en *Máquina de Vectores de Soporte*.
- Diseñar una interfaz amigable de usuario para el uso general del algoritmo de detección del engaño.
- Identificar patrones de la posición de los ojos en las personas cuando dicen la verdad y cuando mienten.
- Analizar la posición de los ojos de un individuo.
- Detectar la posibilidad de que un sujeto mienta analizando los ojos mediante un algoritmo de aprendizaje de máquinas.
- Generar respuesta binaria donde indique si se detecta un engaño en base a la posición de los ojos.
- Crear un programa que permita obtener fotogramas de un video, haciendo énfasis en las microexpresiones faciales del individuo.
- Utilizar un algoritmo de aprendizaje de máquina que reciba como entrada fotogramas de personas respondiendo preguntas y se pueda determinar qué tan probable es que el individuo esté mintiendo, basado en las microexpresiones.
- Comparar los resultados obtenidos con la teoría de engaño en microexpresiones faciales
- Definir un modelo con redes neuronales que analice los datos percibidos mediante Emotiv para determinar la veracidad a preguntas hechas a un sujeto
- Desarrollar un programa que determine, con un porcentaje de confianza de al menos 70, la veracidad sobre las afirmaciones realizadas por un sujeto ante interrogantes, apoyándose en redes neuronales y la información percibida mediante Emotiv
- Determinar la cantidad de neuronas y capas que maximicen la eficacia del modelo creado con redes neuronales trabajando con los datos percibidos por el Emotiv

Los sistemas creados para la detección del engaño más usados están compuestos por dos factores: los parámetros fisiológicos y el modelo usado para producir un comportamiento deseado. Ninguno de estos recaba la información suficiente como para generar conclusiones realmente útiles para el profesional que los utiliza. Esto evidencia la necesidad de estudiar más el fenómeno de la mentira y otros componentes que pueden ayudar al profesional. Además, a pesar de que existe una vasta teoría acerca de la mentira, no se ha logrado trazar el proceso cognitivo por medio del cual se construye la misma. Para superar estas limitaciones, un gran número de estudios recientes han empleado medidas de la actividad cerebral más directas. Las herramientas más utilizadas en estos estudios han sido el Electroencefalograma y la Resonancia Magnética Funcional (Root, s.f.). Estos estudios consideran tanto aspectos verbales, como no verbales, además de la forma en que se procesan las respuestas falsas y verdaderas a nivel cortical y el tiempo de elaboración de mentira. Esto permite comprender que toda acción emocional o conductual conlleva un procesamiento cerebral.

El presente megaproyecto propone la integración de herramientas que miden el comportamiento con aquellas que miden la actividad cerebral, con el propósito de tener un cuadro más completo y eficiente. Esto permitirá detectar patrones en personas que son más propensas a engañar. Se pretende estimar una probabilidad de engaño con el sistema creado.

4.1. Engaño

Existen dos tipos principales de engaño: el ocultamiento o falta de verdad, y el falseamiento o afirmación de algo falso. Se da solo cuando la persona conoce la diferencia entre la información verdadera y la falsa y tiene la capacidad de elegir entre ambas. Aún cuando no se afirma algo falso, decir la verdad a medias es una mentira, pues hay un propósito de engañar. (Ekman, 2014) Ekman identificó que cuando las personas mienten, utilizan diferentes técnicas para ocultar sus emociones. Estas son otras formas de mentir. Una de ellas es usar la sonrisa, pues es una expresión facial fácil de producirse voluntariamente. Además, es parte de saludos convencionales e intercambios sociales. Una segunda técnica es atribuir las emociones a otro motivo para no ocultarlas. Otra técnica, consiste en decir la verdad falsamente o de tal forma que la víctima no la crea. La persona que está engañando puede decir la verdad de manera exagerada y agregándole algunos datos falsos para que parezca sarcasmo o burla. Una última técnica es la evasiva por inferencia incorrecta. Esta consiste en hacer comentarios vagos con el tono de voz y contacto visual adecuados para dar a entender algo que realmente no se piensa. Además, existen dos clases de indicios del engaño: La autodelatación, que es cuando un error revela la verdad; y la pista sobre el embuste, que es cuando un error sugiere que lo dicho o hecho no es cierto, sin revelar la verdad. Estos errores pueden ser expresiones en el rostro, el tono de voz, un desliz verbal, o algunos ademanes que revelan los verdaderos sentimientos de la persona. La mayoría de veces, la autodelatación transmite información valiosa, pero no todo lo que se ha ocultado (Ekman, 2014).

El polígrafo que fue uno de los primeros artefactos en la detección de dicho engaño que su fin inicial era medir los cambios en la presión sanguínea, ritmo respiratorio y cambios galvánicos en la piel (reactividad bioeléctrica de la piel). Estudios han demostrado que cambios en la respiración torácica y diafragmática pueden ser indicadores de estrés o cambio emocional y actualmente, los polígrafos modernos miden estos dos tipos de respiración por separado, lo que incrementa el valor diagnóstico (Vicianova, 2015)

4.2. Procesos cognitivos en el engaño

El cerebro es un sistema muy complejo de diversos procesos que se utilizan para entender el entorno que nos rodea, a través de los sentidos y la interpretación de estos. El cerebro comprende y analiza el entorno a través de la actividad mental y el procesamiento de información de manera efectiva. Para esto, el cerebro utiliza procesos llamados procesos cognitivos, también conocidos como cognición o actividad mental. Esta es la interpretación de la información almacenada en el cerebro a través de la experiencia del día a día. Esta información es adquirida a través de los sentidos y almacenada en la memoria. La cognición ocurre cuando hay asociaciones a partir de una observación o experiencia (Kosslyn, 2008). Dentro de los procesos cognitivos, los que están implicados en el proceso del engaño son los siguientes:

1. La atención, que tiene como objetivo el centrarse en cierta información para procesarla de manera detenida, evitando que otra información se siga procesando. Según Posner y Boies (1971), la atención tiene tres componentes principales: la orientación a los sucesos sensoriales, detección de señales para un procesamiento enfocado y un mantenimiento de estado de vigilancia o alerta (Kosslyn, 2008).
2. La memoria, que es la capacidad de retener y evocar información acerca de experiencias vividas. Muirman que la memoria se “fracciona” en varios niveles de almacenamiento: la memoria sensorial, memoria a corto plazo y memoria a largo plazo; también se sabe que la información pasa de un nivel al siguiente. La memoria de trabajo es parte de la memoria a corto plazo (Etchepareborda, s.f.). Según Baddeley (1990)(Portellano, 2005) Esta se divide en tres: el lazo articulatorio (donde se almacena la información verbal), agenda visoespacial (que gestiona y manipula imágenes visuales) y el ejecutivo central (que es el centro responsable de la planificación, organización, toma de decisiones y ejecución de las tareas cognitivas).
3. Los procesos cognitivos, que se encargan del control de pechos expertos afnsamientos y emociones también es importante. Incluye la atención ejecutiva, la inhibición, la consciencia y otros procesos implicados en la toma de decisiones. Estos procesos controlan funciones como los impulsos, la atención, da un orden cronológico a la información obtenida y manipulada, controla la memoria, lenguaje, cognición visoespacial y las conductas motoras al igual que las emociones (Kosslyn, 2008).

Los procesos cognitivos mencionados anteriormente se encuentran implicados en la elaboración del engaño. Estos, se dan en la corteza prefrontal del cerebro, que, según Lozano y Ostrisky (2011) puede ser clasificada de la siguiente forma: - La corteza prefrontal dorsolateral, se encarga de procesos de complejos, como la metacognición, la cognición social, la conciencia del yo y el autoconocimiento. Lleva a cabo la planeación, memoria de trabajo, solución de problemas, flexibilidad, inhibición y organización de información. - La corteza prefrontal ventromedial, se asocia con procesos de inhibición de respuestas, regulación de procesos atencionales, detección de errores y resolución de conflictos - La corteza orbitofrontal, se encarga de procesos afectivos y motivacionales, que son importantes para la adaptación y el aprendizaje, además de la toma de decisión emocional.

Contar una mentira puede requerir un esfuerzo mental mayor que decir la verdad, debido a que requiere procesos de inhibición de la verdad. Muchos estudios muestran que las áreas cerebrales relacionadas con la memoria de trabajo, conflicto e inhibición de respuestas y la realización concurrente de tareas múltiples se activan al mentir. También han habido estudios que demuestran que mentir conlleva un mayor tiempo de reacción para responder y contienen más errores, y también que si se tiene una mayor capacidad inhibitoria se miente con mayor efectividad y se suprimen conductas que puedan sugerir el engaño. La teoría Activación-Decisión-Construcción-Acción afirma que estos cuatro componentes del acto de mentir implican determinadas operaciones cognitivas que se realizan en la memoria de trabajo, pero requieren de acceso a información almacenada en la memoria a largo plazo (Masip, s.f.).

4.3. Personalidad

Puede definirse como las causas internas que subyacen al comportamiento individual y la experiencia de la persona. Generalmente es utilizada como concepto diferenciador entre individuos, pero también puede definirse con base en la observación de grupos en diferentes niveles. Según esto la personalidad puede clasificarse en diferentes tipos, según personas con características similares. La personalidad también puede ser identificada por medio de rasgos, o características que distinguen a una persona de otra y que ocasiona que cada una se comporte de manera consecuente (Cloninger, s.f.).

4.3.1. Psicopatía

De acorde con Chekley, la psicopatía se define como un trastorno que tiene como síntoma básico la muestra de una deficiente respuesta afectiva general. Cleckley también definió que los psicópatas son incapaces de entender y expresar emociones, aunque tengan comprensión de su lenguaje. Por su parte, Robert Hare define la psicopatía a través de los componentes de su escala, esta se conforma de 20 factores que incluyen aspectos de la personalidad así como de desviación social en los individuos:

1. Percibida locuacidad y encanto superficial
2. Sentimientos de grandiosidad
3. Necesidad de verse estimulado
4. Presencia de mentiras patológicas
5. Manipulación
6. Falta de remordimiento o culpa
7. Afecto superficial
8. Crueldad y falta de empatía hacia otros
9. Estilo de vida parasitario
10. Poco auto-control
11. Promiscuidad sexual
12. Conductas delictivas tempranas
13. Metas poco realistas
14. Impulsividad
15. Irresponsabilidad
16. Falta de responsabilidad ante sus actos
17. Relaciones maritales breves
18. Delincuencia juvenil
19. Libertad condicional revocada
20. Versatilidad delictiva (López, 2009)

4.4. Procesos emotivos

El afecto se define como un rango amplio de sentimientos que las personas experimentan. Puede ser experimentado en la forma de emociones o estados de ánimo. Las emociones son causadas por un evento específico, suelen tener una duración breve y su naturaleza es orientada hacia la acción. El concepto de emoción abarca también desde la experiencia subjetiva (el sentimiento) hasta las reacciones que llamamos vegetativas (sudoración, temblor, palidez) y motoras (gestos, posturas.) (Palmero, s.f.). Las emociones básicas son la ira, el miedo, el desagrado, la alegría, la tristeza y la sorpresa. Estas son reconocidas universalmente. Las emociones generan respuestas faciales, motoras, vocales, endocrinas y autonómicas. Subyacen e interactúan de una serie de mecanismos cerebrales inconscientes que determinan características conscientes. Debido a que los procesos neurales de las emociones son más primitivos que los de la cognición, las respuestas inconscientes se activan de forma más inmediata. Los componentes conscientes no son más importantes que los inconscientes (Belmonte, 2007)

4.5. Las expresiones faciales y las emociones

Las expresiones faciales de las emociones son universales. Se han llevado a cabo diferentes investigaciones, en una de ellas se presentaron cintas que inducían estrés en los participantes. Los participantes eran estudiantes universitarios de Estados Unidos y estudiantes universitarios de Japón. En una parte del experimento el participante observó la cinta solo, mientras que la otra parte fue acompañada de un asistente mientras hablaba acerca de la experiencia. Medidas de los músculos fáciles que se tomaron durante las grabaciones mostraron que, cuando estaban solos en la primera parte del experimento, tanto los estudiantes japoneses como los estudiantes estadounidenses mostraron las mismas expresiones fáciles. En otro experimento, se mostraron fotografías que contenían a una persona expresando una emoción en particular a diferentes participantes de cinco países. Los participantes de estos países debían categorizar la imagen mostrada en una de seis posibles emociones. Se encontró que las expresiones faciales fueron categorizadas de forma bastante similar sin importar el lenguaje, la cultura o el país de origen. (Ekman, 2003)

La sorpresa es la emoción más corta. Esta se puede desencadenar por un suceso inesperado. El suceso puede englobar una idea, un comentario o alguna sugestión por otras personas. El miedo puede ser la emoción que continua a la sorpresa, puesto que algunos eventos que son categorizados por sorpresa pueden ser catalogados como peligrosos y muchas personas suelen asociar lo inesperado con el peligro. El aspecto de un rostro que está expresando la emoción de sorpresa se puede manifestar con las siguientes características: Las cejas pueden estar más curvas y más levantadas, con lo cual se pueden ver arrugas en la frente como consecuencia natural del movimiento de las cejas. Usualmente la sorpresa va junto a una boca abierta y la mandíbula caída. En cuanto a los ojos se puede observar una mayor cantidad de esclerótica justo arriba del iris. (Ekman, 2003)

El miedo es una emoción que es experimentada cuando se tiene la percepción de peligro. Se diferencia de la emoción de sorpresa de tres principales formas. Primero es una experiencia desagradable, va acompañada de cambios en el cuerpo tales como sudoración, dolores estomacales, un aumento en la frecuencia cardiaca y/o también una respiración más rápida. Segundo es que esta emoción puede presentarse en situaciones familiares, que ya han pasado con anterioridad. Y la tercera diferencia es la duración, ya que la sorpresa dura un corto período de tiempo, el miedo es mucho más prologando. Un evento que nos puede sorprender, pero al evaluarlo podemos tener una transición hacia otra emoción. El miedo por otra parte puede durar incluso momentos después de ya no percibir una sensación de peligro. El rostro que está expresando la emoción de miedo se puede manifestar con las siguientes características: Las cejas están elevadas, se diferencia con la sorpresa, ya que la parte interna las cejas están ligeramente más unidas, lo que provoca que las cejas se vean más erguidas. Los ojos están abiertos y tensos durante la emoción, se diferencia con la sorpresa en la parte inferior del parpado,

ya que esta se muestra tensa y levantada, comparada con la sorpresa, esta parte puede llegar a cubrir el iris. La boca aparece abierta, pero los labios están tensos y pueden estar ligeramente hacia atrás. A pesar de que todas las características pueden ocurrir todas en conjunto, también puede ocurrir de forma aislada. El rostro puede expresar varios grados desde miedo hasta terror. (Ekman, 2003)

El asco es una emoción de aversión. Esta emoción puede ser provocada por un sabor, un olor, un pensamiento, un sonido e incluso acciones o ideas de otra persona. Lo que es repulsivo para una persona, no necesariamente es para otra persona, esto varía dependiendo de la cultura y de las experiencias de cada persona. El desprecio se podría considerar la emoción más cercana a el asco. El desprecio se puede experimentar respecto a personas o acciones de otras personas pero no acerca de gustos, olores o de contacto. Los mayores indicios de que una persona está manifestando asco es en la boca, la nariz, y de una manera menor en los párpados inferiores y la cejas. El labio superior puede estar elevado, causando un movimiento en la punta de la nariz. Entre mayor sea la emoción expresada, mayores serán las arrugas en la sección de la nariz. El labio inferior puede estar levantado o bajado. Las mejillas están levantadas y esto produce un cambio en los párpados inferiores, esto se puede apreciar con un estrechamiento de la apertura de los ojos con líneas y pliegues debajo de los ojos. El asco puede mezclarse con otras emociones. En el caso de la sorpresa, puede ocurrir que una persona le produzca repugnancia una acción que fue inesperada, y la emoción de sorpresa aún está presente. En el caso de que se mezcle con el miedo, puede ocurrir si se presenta algo que es temido mientras le causa aversión a la misma persona. Sin embargo, es más común que se mezcla con la emoción de la ira. (Ekman, 2003)

La ira es la emoción más peligrosa. Ya que parte de la experiencia de la ira, es el riesgo de perder el control. Generalmente a los niños se les educa de diferente forma que las niñas, respecto a cómo actuar ante la ira. Es más común que a una niña se le eduque para que no muestra la emoción de ira ante nadie, mientras que a los niños que expresen la ira hacia sus compañeros si estos lo provocan. La ira puede ser despertado de diferentes formas, entre ellas se encuentra la frustración provocado por la interferencia en una actividad o interferencia en la persecución de una meta, una amenaza física, por la acción o declaración de una persona que causa un dolor psicológico o también por el observar a alguien realizar algo lo cual viola los valores morales propios. Existen diferentes reacciones físicas ante la ira, en estas se puede encontrar un incremento de la presión, el rostro se puede tornar rojo, las venas en la frente y el cuello se pueden hacer presentes, la respiración cambia, los músculos se tensan. Se pueden notar ciertos cambios en el rostro de una persona que experimenta el enojo, principalmente en las cejas, los ojos y la boca. Al haber cambios en estas tres secciones de la cara, se puede determinar que una persona está enojada, de lo contrario no resulta claro si la persona está expresando esta emoción. Las cejas están hacia abajo y juntas, esto provoca que las esquinas internas de las cejas produzcan una arruga vertical entre ambas cejas, no se presentan líneas horizontales en la frente. Con la expresión de las cejas no es posible determinar si la persona está sintiendo ira o no, puede ser que la persona está sintiendo ira, pero la esté intentando ocultar, que la persona está ligeramente molesta o que este en un modo serio. En los párpados se pueden ver tensos y los ojos parecen ver de una forma penetrante. La boca en un estado de ira puede presentarse en dos tipos básicos, una es la presión de labio inferior contra el labio superior y una boca abierta de forma cuadrada. La intensidad de la ira se puede manifestar en que tan tensos están los párpados o que tan abultados están los ojos. También que tan presionados los labios están entre sí, en cuanto a las cejas se podría observar que tan juntas y tensas están entre ellas. (Ekman, 2003)

La felicidad es la emoción que la mayoría de las personas quieren experimentar y se puede considerar una emoción positiva. Esta emoción puede variar en su tipo, y también en la intensidad. La sonrisa, que suelen ser parte de la felicidad también puede mostrarse aun cuando la emoción de felicidad no está presente, por ejemplo, se puede tratar de ocultar una emoción con una sonrisa. Una sonrisa puede indicar, sumisión ante algo que no es placentero, o usada en situaciones donde una persona se encuentra tensa. En una expresión de felicidad hay una apariencia distintiva en los párpados y en la parte inferior del rostro, sin embargo, las cejas y la frente no necesariamente se ven involucradas en esta expresión. Un indicio son las esquinas de los labios, estos suelen estar un poco elevados. Los labios pueden permanecer juntos, también los labios podrían estar separados con los

dientes unidos o la boca podría estar abierta mostrando los dientes. Se pueden también presentar arrugas que van desde la nariz hacia la parte superior de la esquina de la boca, a esta se le conoce como los pliegues naso labiales, y son indicadores de una expresión fácil feliz. Adicionalmente a esto, las mejillas se elevan cuando hay una sonrisa pronunciada, intensificando los pliegues naso labiales. En cuanto a los párpados inferiores se pueden encontrar arrugas en la parte inferior de ellos, y la estos pueden mostrarse levantados sin llegar a presentarse tensos. La felicidad se puede mezclas con otras emociones. En el caso de la sorpresa, se podría dar el caso en donde ocurra algo inesperado, y al evaluar dicho evento resulta ser algo beneficioso. Lo más notable es en la parte inferior del rostro, se puede dar la combinación entre labios abiertos de sorpresa, pero las esquinas de los labios pueden mostrarse ligeramente como una sonrisa. Otra mezcla de emociones se podría dar entre la ira y la alegría, en muchos casos se puede intentar mezclar la ira con una sonrisa por lo tanto la mezcla se daría entre las cejas y la frente mostrando características de ira y en la parte inferior del rostro mostrar características de felicidad. (Ekman, 2003)

La tristeza es una variación o forma de distrés y generalmente es la emoción más negativa que se puede experimentar. Existen características visibles en tres áreas faciales cuando la emoción de tristeza está presente, en las cejas, en los ojos y en los labios. En cuanto a las cejas, las esquinas internas suelen estar levantadas y pueden estar más unidas. Este movimiento de cejas puede estar acompañado de un cambio en la parte inferior de los párpados y en la parte inferior de la cara, sin embargo, puede ocurrir de forma aislada indicando que la persona siente ligeramente tristeza. En cuanto a los ojos, se puede apreciar que estos están ligeramente hacia abajo. En el caso de la boca se puede ver que las esquinas de los labios están hacia abajo. Al solo tener en consideración la boca se podría confundir con otras emociones. (Ekman, 2003)

4.6. Inteligencia Emocional

4.6.1. Modelo mixto

Ve la inteligencia emocional como un conjunto de rasgos estables de la personalidad, junto con competencias socio-emocionales, aspectos motivacionales y habilidades cognitivas del individuo (Fernandez, N; & Extremera, 2005).

4.6.2. Modelo de habilidad

La inteligencia emocional como una inteligencia genuina y que se basa en el uso adaptativo de emociones para la resolución de problemas dentro del medio propio, así como su aplicación al pensamiento personal (Fernandez, N; & Extremera, 2005).

4.6.3. Modelo de Salovey y Mayer

Explica la inteligencia emocional a partir de las cuatro habilidades básicas: percibir emociones con exactitud, generar sentimientos que faciliten el pensamiento, comprender las emociones y el conocimiento emocional y regular emociones promoviendo el crecimiento emocional e intelectual (Fernandez, N; & Extremera, 2005).

4.7. Creencias sobre el engaño

Según la investigación “A world of lies” (Global Deception Research Team , 2006) hay varias creencias sobre factores que indican cuando alguien está mintiendo mediante a su comportamiento corporal. En la investigación se realizaron estudios en 75 países distintos y en 43 idiomas distintos. Los estudios constaban de realizar dos entrevistas distintas a las personas. La primera entrevista era para ver qué es un factor que indica cuando una persona miente. Es importante mencionar que en la mayoría de las entrevistas las personas dieron más de una respuesta y todas se tomaron en cuenta. La siguiente gráfica indica cuales fueron las respuestas más comunes. Como se puede apreciar, más

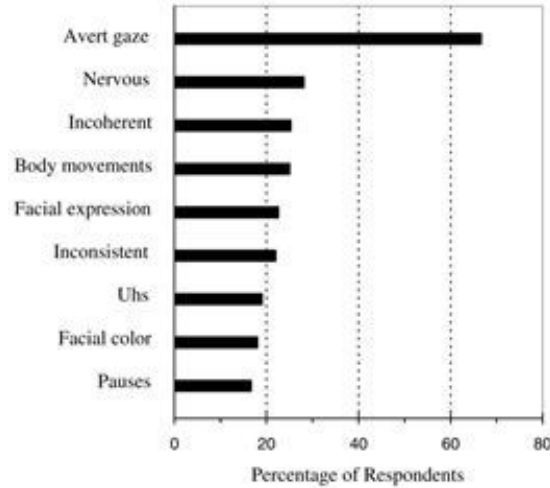


Figura 4.1: Gráfica de respuestas de la primera encuesta (G. D. R. Team, 2006)

del 60 % de los entrevistados incluyeron que apartar la mirada es un índice sobre cuando las personas mienten. Luego de este análisis hicieron la otra entrevista. La siguiente gráfica indica cómo la gente percibe los distintos aspectos y creencias sobre la mentira. Nuevamente podemos observar que la

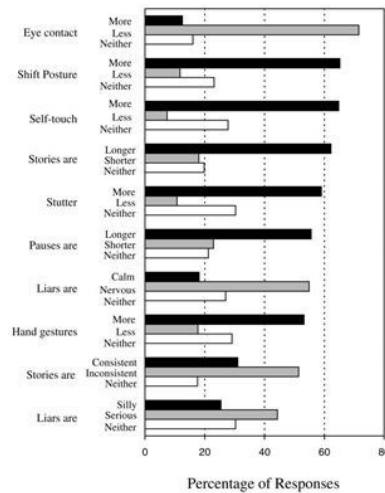


Figura 4.2: Gráfica de respuestas de la primera encuesta (G. D. R. Team, 2006)

gente considera que desviar la mirada o tener menor contacto visual es significativo. Lo interesante

de estos resultados es, como se mencionó antes, una creencia mundial. No es una creencia que existe solo en ciertos países de una región del mundo, pero es una creencia que se encuentra al menos en todos los países en los que se hicieron las entrevistas. La lista de países incluye tales como Francia y Egipto hasta Pakistán y Paraguay. Solo en estos países ya se tiene muchas diferencias culturales. Entonces de cierta forma es curioso pensar de donde vienen estas creencias. Pero más importante qué tan reales son.

4.8. El engaño y el rostro

Las expresiones faciales de las emociones presentan cierto grado de dificultad al intentar monitorearlas, y hay dos razones detrás de esto. Primero es que las expresiones faciales pueden ser extremadamente rápidas y segundo que esta es una fuente de información menos precisa, que otras tales como la voz. Las expresiones faciales pueden llegar a ser involuntarias en caso de que sean activadas por una emoción. Debido a que las personas tienen una menor práctica en controlar sus expresiones faciales, han ido desarrollando técnicas para el manejo facial, y esto puede provocar que se anule una expresión facial involuntaria o que se llegue a expresar un rostro que no refleje la emoción que se tiene en ese momento. Cuando la persona no intenta controlar el mensaje que está transmitiendo, la información internamente consiste, y se puede decir que la comunicación es honesta. Por otro lado, las personas intentan controlar el mensaje, tratando de ocultarlo y sustituirlo por otro, por lo tanto, los mensajes están en conflicto, ya que uno expresa el sentimiento actual mientras el otro refleja lo que la persona intenta transmitir. (Ekman, 2003)

Existen algunas técnicas conocidas para el manejo facial, entre ellas se encuentran la de calificar la expresión, modularla o falsificarla. Cuando se califica, se agrega una expresión justo después de mostrar la expresión inicial. En este caso la emoción sentida no es cambiada en cuanto intensidad, como en el caso de la modulación, ni es reemplaza como el caso de la falsificación. Esto puede ocurrir por reglas culturales o personales o como una expresión genuina a un sentimiento adicional. La sonrisa es la que más frecuentemente se utiliza, agregada como complemento a las emociones negativas. Esta puede dar una pauta de los límites o consecuencias de la emoción negativa que se está sintiendo, ya que informa a la otra persona que todavía se está en control de la situación. Por ejemplo, si se califica a una expresión de enojo con una sonrisa se puede interpretar de la manera en que el enojo está siendo limitado. El calificar a una expresión facial se la forma más moderada del manejo facial. Esta distorsiona muy poco y es usualmente el resultado de reglas culturales o personales. La distorsión del mensaje es mínima, y la evidencia que esto está ocurriendo suele ser obvia. (Ekman, 2003)

En cuanto a la modulación de una expresión facial, se ajusta la intensidad de la expresión para mostrar menos o más de lo que realmente se siente. Existen tres maneras de modular una expresión facial, se puede variar el número de áreas involucradas, la duración de la expresión o como se muestran los músculos faciales. Un ejemplo de la modulación podría ser que una persona que está sintiendo miedo intente disminuir la intensidad mediante algunos de los siguientes cambios en el rostro: Eliminar la expresión de miedo de la boca y de los ojos, acortar el tiempo que dura la expresión original o intentar disminuir el pronunciamiento de los labios para no mostrar la emoción de miedo. Generalmente cuando una persona modula, intensifica o la disminuye la intensidad se usarán las técnicas que se mencionaron. (Ekman, 2003)

En la falsificación de una expresión facial, se muestra una emoción cuando no se tienen una, no se muestra una emoción cuando realmente si se está sintiendo de una manera o se cubre la emoción con la apariencia de otra la cual no se está sintiendo. A cada una de estas tres categorías se les conoce como neutralización, simulación y enmascarar. En la simulación la persona intenta dar la impresión de que no se está sintiendo ninguna emoción. Para lograr esto de forma exitosa, es necesario recordar la sensación que dé como la emoción se debe reflejar en el rostro, para que así voluntariamente se pueda ajustar el rostro. La neutralización es el contrario de la simulación. En esta se puede tener una

fuerte emoción, pero en el rostro que se intenta mostrar una expresión neutral. En este caso se está removiendo la intensidad de la emoción, ya que la expresión está siendo modulada hasta el punto en donde no se muestra nada. En una expresión facial que está llevando a cabo la neutralización, se puede inhibir cualquier contracción muscular, intentar congelar los músculos faciales, hacer un camuflaje del rostro mediante acciones como morder el labio, succionar el labio, frotarse los ojos, o frotarse alguna otra parte del rostro. La neutralización es bastante compleja de llevar a cabo, en especial en eventos fuertes o eventos en donde se esperaría una reacción. En estos casos se puede ver a la persona tensa lo cual puede dar indicio que se está falsificando la expresión. (Ekman, 2003)

El enmascaramiento se simula una emoción que no se está sintiendo, para cubrir u ocultar otra emoción que si está sintiendo. Por ejemplo, en el caso que una persona sienta disgusto para lo cubre con expresión triste, entonces estaría en esta categoría. Las personas usan el enmascaramiento porque es más sencillo ocultar una emoción con otra que el poder no mostrar ninguna emoción en absoluto. La sonrisa es también utilizada para enmascarar, al igual que la de calificar una expresión. Anatómicamente, la sonrisa es una forma facial de ocultar una apariencia en la parte baja de la cara en emociones negativas tales como la ira, el miedo, la tristeza y el asco. Además de ello en las situaciones sociales se desea ocultar una emoción negativa con un mensaje más empático. (Ekman, 2003)

Existen ciertos aspectos que pueden llegar a determinar si una persona está intentando controlar sus expresiones faciales. El primero es la morfología, la cual hace referencia a configuración de la apariencia del rostro. El segundo aspecto es el tiempo de la expresión, que tanto tiempo tarda en aparecer. El tercer aspecto es la posición de la expresión en la conversación y la cuarta es conocida como expresiones micro-faciales. (Ekman, 2003)

En la morfología, hay que presentar atención en lo que la persona hace en la parte baja de rostro, especialmente en los labios y las líneas alrededor de la nariz y las mejillas inferiores. A pesar de no tener evidencia de esto, los estudios sugieren que cuando una persona está controlando lo que se muestra en su rostro, un mayor esfuerzo ocurre en la parte de la boca y labios que en el área de los ojos y párpados o de las cejas y la frente. Esto puede ocurrir debido al rol que toma la boca al momento de hablar. Cuando se está modulando una expresión facial, es más probable que se intente manejar la boca. Por ejemplo, en el caso que se está modulando una expresión facial de miedo, intentando quitar intensidad a la apariencia de la emoción, es muy probable que elimine las señales de miedo de la boca. En el caso de una falsificación de una expresión facial, también la boca es el principal foco para manejar la emoción. En el caso que se use la neutralización, es muy probable que la expresión desaparezca de la boca. Por otro lado, si se está simulando una expresión, es más probable que la expresión falsa aparezca en el área de la boca. También sucede en el caso enmascaramiento, es muy probable que el foco principal de atención sea la boca. (Ekman, 2003) Generalmente cuando una persona manipula ciertas áreas de su expresión facial para falsificar a modular, está área manipulada puede afectar a otras. Por ejemplo, al intentar controlar secciones tales como las cejas y frente, puede afectar como se ven al pate de los párpados superiores. Para poder predecir las señales de engaño cuando se esté aplicando una modulación o falsificación en cada una de las seis emociones principales, depende no solo de las tres diferentes áreas faciales que están siendo involucradas, sino también de que tanta práctica tenga la persona realizando ese movimiento en particular. (Ekman, 2003)

Para reconocer señales de engaño en la expresión de felicidad, se debe tomar en cuenta que está emoción no involucra la parte de las cejas y la frente. Si alguien está simulando esta expresión, podemos esperar no encontrar ninguna señal de engaño en esta sección debido a que la persona no está involucrado, en caso contrario si se está utilizando la expresión de felicidad para enmascarar una expresión, podemos esperar que en la parte de las cejas y la frente no esté involucrada, y podemos esperar la fuga de la emoción que está sintiendo en la parte de las párpados superiores y también en la frente y cejas. Por otro lado, en el caso de la modulación, específicamente en la parte de desintensificación de la expresión de felicidad, puede haber una señal que se quede en la parte de las mejillas, hoyuelos en la parte de los labios. En la emoción de sorpresa, al ser relativamente sencillo de

simular, la única señal de engaño podría ser la ausencia de la expresión de los párpados. La sorpresa también puede ser utilizada para enmascarar otras emociones. En este caso la señal de engaño será la duración, debido a que la expresión de sorpresa suele ser una emoción corta, por lo tanto, la prolongación de esta puede dar indicios que es falsa. En la expresión de miedo, en el caso de la simulación, es probable que se tenga boca con expresión de miedo y ojos fijos, entonces un indicio podría ser una falta de movimiento en cejas y frente. Por otro lado, cuando una persona muestra una expresión de miedo en las cejas, es probable que sea genuino debido a la dificultad de realizar este movimiento de forma voluntaria. Cuando el enojo es simulado, puede no haber señales claras de engaño en las diferentes áreas faciales. El emblema de las cejas juntas que muestran pliegues entre las cejas es un emblema de la concertación o determinación. Y al ser una expresión muy fácil de hacer, se puede esperar que la parte de las cejas y la frente sean parte de una expresión de enojo simulado. En el caso de enmascaramiento, se mostrará el enojo en la parte baja de la cara y en la sección de las cejas y frente, dejando solamente a los párpados como la emoción que se está sintiendo. En el caso el asco, también es sencillo simularlo, existen tres emblemas distintivos, el arrugamiento de la nariz, el levantamiento de labio superior o levantamiento de un lado de labio superior. Las cejas y rente juegan un papel mínimo en esta expresión facial, por lo que en un caso de enmascarar el asco con por ejemplo el enojo, se podría observar justo en esta sección del rostro. Sin embargo, también puede ser una mezcla de emociones, pero esto dependerá del contexto social, específicamente en lo que la persona está diciendo y haciendo. Cuando la tristeza está siendo simulada, es probable que se muestre en la parte baja del rostro y en la parte inferior de los ojos. La ausencia de una expresión de tristeza en la parte de cejas y la parte superior del parpado, pueden ser una buena señal que la tristeza está siendo simulada. Al ser una expresión difícil de realizar de forma voluntaria, una expresión de tristeza en las áreas mencionadas anteriormente puede dar indicios que es una expresión genuina. En el caso de que una persona esté intentando desintensificar la emoción de tristeza, en las secciones de las cejas y frente se podrá ver la intensidad genuina de la emoción. (Ekman, 2003) El cronometraje es un factor importante en el manejo facial. Esto involucra factores tales como el tiempo en que tarda una expresión en mostrarse, el tiempo en que la expresión se queda en el rostro, cuanto tiempo tarda en que la expresión desaparezca del rostro. Este factor depende mucho del contexto social. Se debe observar cuidadosamente, los tiempos de cada persona debido a que no existen tiempos establecidos en cada una de las emociones. (Ekman, 2003)

Las microexpresiones, al momento de modular, neutralizar y enmascarar una expresión facial, algunas veces una persona interrumpirá una expresión que está ocurriendo, en lugar de interceptarla antes de cualquier movimiento muscular se presente. Esto provee otra fuente de señales de engaño. Aunque la mayoría de las expresiones faciales duran más de un segundo, las microexpresiones suelen durar entre una quinta parte y una veinticincoava parte de segundo. Algunas de estas microexpresiones son el resultado de interrupciones. Por ejemplo, se empieza a sentir miedo, y la expresión facial comienza a aparecer en el rostro, entonces se empieza a sentir que los músculos de cara están tomando una expresión de miedo, esto provoca que se empiece a modular, neutralizar o enmascara esta emoción. Por lo tanto, en una fracción de segundo, la expresión de miedo estará en el rostro de la persona. Las microexpresiones son generalmente incrustadas en el movimiento, a menudo en movimientos faciales que son parte de hablar. Algunas microexpresiones, no muestran suficiente información para determinar que emoción se está intentando modular, neutralizar o enmascarar. A pesar de ello estos pequeños fragmentos de expresiones faciales pueden ayudar a encontrar señales que una persona está manejando sus expresiones faciales. Muchas personas podrían no mostrar microexpresiones y esto no quiere decir que la persona no esté intentando controlar sus expresiones faciales. Otras personas podrían mostrar señales de engaño en los otros puntos mencionados. E incluso se puede mostrar microexpresiones en ciertas situaciones, pero en otras no. (Ekman, 2003)

4.9. Neurología de la psicopatía e inteligencia emocional

Entre las áreas más importantes para el estudio de tanto la psicopatía como las emociones es la corteza prefrontal. Es la parte más evolucionada del cerebro y entre sus funciones se encuentran el control ejecutivo del cerebro, pero también la capacidad de formar objetivos y planes para su ejecución, esta capacidad siendo considerada un aspecto esencial en la madurez de la personalidad (Amen, 2011). Estas y otras funciones se generan desde las tres secciones principales de la corteza prefrontal: la lateral dorsal, la orbital inferior y el giro cingulado.

- **Corteza prefrontal ventromedial:** Esta área de la corteza prefrontal se asocia con la habilidad de las personas en mostrar empatía y manejo de conocimientos pro social. Se ha encontrado que en sujetos con psicopatía, existen diferencias significativas en estas áreas, como la reducción de la materia gris (De Oliveira-Souza, 2008).
- **Corteza orbitofrontal:** Se asocia con lo que es la regulación del comportamiento y reversión de respuestas. Estudios en individuos indican diferencias en estas áreas de su cerebro en comparación a sujetos sin este desorden, presentándose también una reducción en la cantidad de materia gris (De Oliveira-Souza, 2008), así como cambios en la anticipación al castigo y recompensa (Glenn et al., 2008) y niveles reducidos de miedo (Van Honk y Schutter, 2006).
- **Corteza prefrontal medial:** Asociada con la respuesta ante emociones. Diferencias encontradas en esta área en los psicópatas indican menos capacidad de respuesta cuando se ven expuestos a un estímulo emocional (Van Honk, s.f.).
- **Corteza prefrontal orbitomedial:** Esta área tiene relación con la capacidad de Lectura emociones en las personas y toma de decisiones, individuos con psicopatía presentan dificultades en cuanto a reacciones apropiadas ante situaciones emocionales (Van Honk, s.f.).
- **Sistema límbico:** Área cerebral que envuelve y rodea el tallo encefálico, asociado comúnmente con el componente de respuesta emocional en el cerebro. Tiene conexiones con el neo córtex y se asocia con los sistemas de memoria y aprendizaje (Goleman, 2012).
- **Corteza frontal en el control emocional:** Existe una vía nerviosa que conecta los lóbulos prefrontales con el sistema límbico, esto determina que diferentes señales emocionales puedan influir en la memoria de trabajo y otras funciones de manejo ejecutivo (Goleman, 2012).

4.10. Sonido

Sonido es la palabra que utilizamos para referirnos a las vibraciones que los humanos somos capaces de escuchar, para examinar la naturaleza del sonido se debe entender los conceptos: frecuencia, espectro de audio y tono. (Hurtig, 1988)

Los sonidos son ondas muy complicadas por tener muchos componentes de diferente índole que evolucionan muy rápidamente en el tiempo por lo que su análisis y estudio resulta bastante moroso. (Gérard, 2011)

4.10.1. Almacenamiento - WAV

WAV (Wave Form Audio) es un formato de archivo utilizado para almacenar sonidos en su forma de onda. Un minuto de sonido utilizando modulación por impulsos codificados (PCM por sus siglas en inglés) puede ocupar desde 644 kilobytes hasta 27 megabytes, dependiendo de la frecuencia de muestreo, si se graba en mono o estéreo y la cantidad de bits utilizada para cada muestra. (Microsoft, 2018)

4.11. SoX - Sound eXchange

SoX (Sound eXchange) es una utilidad de línea de comandos multiplataforma (Windows, MacOS, Linux) que permite realizar operaciones sobre archivos de audio. (Bagwell, 2013) Su función más utilizada es la conversión de formato de archivos, sin embargo también provee funcionalidades para aplicar efectos, modificación de volúmenes, efectos de producción y análisis. Dentro de la información que provee la función de análisis se encuentran:

4.11.1. Decibel

El decibel es una unidad de medida utilizada para expresar la relación del valor de una propiedad física a otra en una escala logarítmica. Puede ser utilizado tanto para representar un cambio relativo (eg. +1 dB o -1 dB) como un valor absoluto.

El uso más común del decibel es en el campo del sonido, específicamente en la medición del nivel de presión del sonido. (Rose, 2002)

Presión del sonido

La presión del sonido es una desviación de presión local respecto a la presión atmosférica ambiental. En aire la presión del sonido puede ser medida con un micrófono, y en el agua con un hidrófono. La unidad de medida en el Sistema Internacional para la presión del sonido es el pascal (Pa). (Winer, 2012)

Nivel de presión del sonido

El nivel de presión del sonido (SPL por sus siglas en inglés) es una escala logarítmica de la presión del sonido respecto a un valor de referencia, el cual usualmente es de $20 \mu Pa$, que es considerado el mínimo que el oído humano puede distinguir (aproximadamente el sonido de un mosquito volando a una distancia de 3 metros.) (Winer, 2012)

4.11.2. Factor de cresta

El factor de cresta es una medida de una onda, como el sonido. Mide la relación entre los valores pico y el valor cuadrático medio (RMS), es decir, mide qué tan extremos son los picos en una onda. (JBL, s.f.)

4.12. Electroencefalografía

Para la medición la actividad cerebral, específicamente del lóbulo frontal para este trabajo se conoce el método de la electroencefalografía. Es un método de monitoreo que consiste en grabar la actividad energética del cerebro. Es un método por lo regular no invasivo médicamente y lo que mide son los cambios en el voltaje que resultan de las corrientes eléctricas creadas por las neuronas en cierto periodo de tiempo. Es utilizado para diagnosticar enfermedades cerebrales, pero también puede ser utilizado para investigación suponiendo que el estímulo que se le dé al sujeto sea suficiente para que se pueda registrar en el cerebro. (Niedermayer, s.f.)

4.13. Emotiv

El dispositivo Emotiv es un dispositivo diseñado para obtener señales electroencefalográficas mediante sensores colocados sobre el cráneo. Este dispositivo mide con 14 sensores, empapados en solución salina, la actividad electroencefalográfica del cerebro humano de forma superficial. Los sensores son colocados como se puede observar en la Figura 4.3 para obtener la mayor cantidad de datos con la mayor fidelidad. (EPOC, 2003)




Figura 4.3: Mapa de sensores que cubre el dispositivo Emotiv (EPOC, 2003)

4.14. Aprendizaje estadístico

El aprendizaje estadístico se define como los acercamientos o métodos utilizados para poder encontrar una función f , que representa una entidad en la vida real, que se encuentra en:

$$Y = f(X) + \epsilon$$

Primero se asume que, Y y X tienen una relación, la función f representa la información sistemática de Y provista por X . Donde X es un conjunto de variables introducidas al modelo, influyentes en la entidad de la vida real. $X = (X_1, X_2, \dots, X_n)$ y ϵ representa el error que conlleva el modelo. Por ejemplo, si se quisiera hacer un modelo para un estudio de las ganancias con respecto al dinero invertido a la televisión, la radio y el periódico, las ventas serían nuestra variable dependiente (Y) y el dinero invertido, por cada uno de los medios de entretenimiento, sería la variable independiente(X).




Figura 4.4: Ejemplificación de datos sobre publicidad. Se muestran las ventas en unidades (millones) en función del presupuesto de TV, Radio y periódico en millones de dólares. Se utilizó una regresión lineal para predecir dichas ventas (Casella y cols., 2006)

La razón para encontrar el comportamiento de la función que modela a las variables X , es para poder:

1. Predecir
2. Inferir

La predicción se hace cuando tenemos el conjunto de variables X , pero no se puede obtener el modelo Y exacto. De ser así el error se vuelve aproximadamente 0. Por lo tanto, se predice Y usando:

$$\hat{Y} = \hat{f}(X)$$

Donde \hat{f} es el estimado para la función real f y \hat{Y} que representa la predicción de Y . De forma que se pueda tratar \hat{f} como una caja negra de distintos métodos para poder acertar predicciones la precisión de \hat{Y} como predicción de Y depende de dos cantidades, el error reducible y el error irreducible. El simple hecho que \hat{f} no es la función exacta f se la falta de precisión introduce error, el cual se puede reducir con técnicas provistos por métodos de aprendizaje estadístico. El otro error surge de la función original Y que tiene un error ϵ , que proviene de no conocer todas las variables en X .

La inferencia no consiste en hacer predicciones hacia Y en cambio, el objetivo de la inferencia es hallar la relación que hay entre Y y X , específicamente entender como Y cambia al ser una función descrita por los elementos en X , esta relación puede estar descrita por las variables que afectan al modelo, como lo afectan y el tipo de relación entre las variables. Para las predicciones e inferencias se pueden utilizar modelos:

- Lineales: El proceso de inferencia puede ser simple de interpretar, pero no nos ayudan a predecir
- No-lineales: Mejores predicciones, pero la interpretación requiere de mayor contexto sobre las

Para poder asegurar que un algoritmo realizará una predicción acertada se necesita observaciones previas para el algoritmo. Esto se denomina información de entrenamiento, que servirá para inducir

a los algoritmos o métodos una prueba y que ellos identifiquen patrones en la información para luego contribuir con predicciones. Estos métodos que necesitan de un entrenamiento se pueden categorizar como métodos no paramétricos y paramétricos.

Los problemas para los que se utilizan los métodos pueden ser de regresión o de clasificación. Cuando se hace una regresión se espera una respuesta cuantitativa, mientras que si se trata de un problema de clasificación se espera una respuesta cualitativa. Existen métodos exclusivos para cada tipo de problema, hay excepciones donde el método se puede utilizar para ambos tipos de problemas como lo es el algoritmo del K-ésimo vecino más cercano (KNN)(Casella y cols., 2006).

4.15. Métodos no-paramétricos

Estos no hacen la suposición inicial sobre el comportamiento de la función f , por lo tanto, los algoritmos se pueden acoplar a distintos comportamientos de dicha función. Se utiliza la información para generar el modelo, el método recibe la información sin conocer que comportamiento tiene, generando una aproximación, sin ser exacta. Sin embargo, hay una desventaja y es que la información es extensa, por lo tanto, no hay reducción a parámetros, es decir se trata de encontrar un modelo que tenga una tasa de eficacia alta. Hay que encontrar una función y sus parámetros, agregando una tarea más a este método. (Casella y cols., 2006)

Este tipo de métodos no requieren de un análisis previo extenso ni de pruebas preliminares para hallar un modelo adecuado, es cuestión de saber que variables influyen en el modelo predictivo que se quiere crear. Como se mencionó anteriormente se usan los datos puros, porque todos influyen en el modelo, los cuales pueden sobrecargar el método al momento de hacer una predicción, tanto que su eficiencia se ve afectada. Los métodos son percibidos como prohibitivos por el simple hecho de que la complejidad computacional y el espacio dimensional de la información son altos. (Liu, 2017)

4.16. Transformada de Fourier

El análisis de audio y manipulación de este le debe mucho a distintos científicos que se dedicaron a analizar las ondas que el sonido produce. Dentro de los científicos que más destacan se encuentra Jean Baptiste Fourier, quién desarrolló métodos para descomponer una onda compleja en pequeñas partes. Lo que resulta más interesante de este método es que es bastante sencillo demostrar que al sumar las distintas partes se puede reconstruir la onda compleja que generó las pequeñas partes.

La transformada de Fourier posee dos aplicaciones de mucho interés, pero para motivo de esta investigación nos centraremos en una. Sus aplicaciones son de descomponer una onda compleja en sus partes como se mencionó anteriormente y la segunda, que es la que nos interesa, obtener las diferentes frecuencias. Su estudio se centró en transferir una función representada en el dominio del tiempo a representar esta función en el dominio de la frecuencia. El dominio es un termino que se utiliza para describir el análisis de señales o funciones matemáticas respecto a su frecuencia. Este método se le llama específicamente la Transformada Discreta de Fourier.




Figura 4.5: Transformada de Fourier.

4.17. Inteligencia artificial

La inteligencia artificial es una rama muy extensa de las ciencias de la computación. Ha tenido muchas definiciones a lo largo de la historia desde su primer reconocimiento donde se introdujo como cualquier automatización de actividades que para un ser humano implicaría el uso de su inteligencia. En esta definición se adjunto la toma de decisiones, la resolución de problemas y el aprendizaje entre otras. Después fue descrita más hacia una definición del estudio que hace la computación posible percibir, razonar y actuar. Actualmente está definido simplemente como el diseño de agentes inteligentes donde abarca muchas ramas del análisis de datos y las acciones que logran por el mismo análisis.

4.18. Aprendizaje supervisado

Los métodos utilizados en aprendizajes supervisados intentan extraer aquellas propiedades que permiten discriminar mejor la clase de cada conjunto de datos, y como consecuencia requieren de una clasificación previa (supervisión) del conjunto de entrenamiento. Es una formalización para los sistemas de cómputo que aprenden a partir de ejemplos. El sujeto que aprende (generalmente un programa de computación) contiene dos conjuntos de datos, el que se mencionó anteriormente que es el conjunto de entrenamiento y otro el de pruebas. La idea básica es que el sujeto que aprende pueda ponerles una etiqueta a los datos que no han sido clasificados, a partir de la información que utilizó para poder clasificarlos. (Erik G., 2014)

La información de entrenamiento consta de n pares ordenados $(x_1, y_1), (x_2, y_2) \dots (x_n, y_n)$, donde cada x_i es una propiedad, medida o conjunto de estas de un solo punto de información de ejemplo, y y_i es la etiqueta para ese punto. La información de prueba es otro conjunto m medidas sin etiquetas $(x_{n+1}, x_{n+2}, \dots, x_{n+m})$. (Erik G., 2014)

4.18.1. Clustering

Existen herramientas de gran utilidad en la inteligencia artificial para el entendimiento y análisis de los datos. Clustering es una de estas herramientas. La idea principal del análisis por clustering es encontrar automáticamente grupos o clusters significativos en los que todos los integrantes tienen características en común. Ha tenido aplicaciones en muchos campos como inteligencia de negocios, psicología, aplicaciones para la web, etc. (Wu, 2012) Existen varios algoritmos para este análisis. Un algoritmo de clustering utilizado desde 1957 y que se sigue utilizando es el de K-Means. En resumen, este algoritmo intenta encontrar clusters que no se superponen agrupando todos los elementos a otros elementos centrales por sus características, el número de elementos centrales es especificado antes. Continuamente agrega elementos a los centrales y los modifica hasta ya no tener elementos. (Wu, 2012)

4.18.2. Método del codo

Un problema bastante frecuente a la hora de realizar un agrupamiento se encuentra en saber cual es el número ideal de grupos que se debe realizar. Para resolver esta problemática se han implementado diferentes métodos que apoyan en la elección del número apropiado de clusters para el agrupamiento de datos y dentro de ellos, se encuentra el método del codo.

Este método utiliza los valores de inercia que se obtienen luego de aplicar el K Means a diferente número de cluster. Se define como inercia a la suma de las distancias al cuadrado de cada objeto del cluster a su centroide. (Kumar, 2014)

4.18.3. Árbol de decisión

Los árboles de decisión son otra herramienta muy útil en la inteligencia artificial. Un árbol de decisión es un diagrama secuencial que ilustra todas las posibles decisiones que se alternan para llegar a los resultados correspondientes. En un árbol de decisión cada nodo interno representa en lo que se basó la decisión, cada rama hija representa como esa decisión lleva a otras y las hojas representan un resultado. Esta herramienta permite ver de manera general en que se podría basar un clasificador y que variables son útiles para las decisiones gracias a su algoritmo. (Liu, 2017)

4.19. Minería de texto

La minería de texto tiene como objetivo principal extraer información que resulte útil y relevante a partir de páginas web, correos electrónicos, artículos, entre otros. La recolección de datos se puede realizar mediante la identificación de patrones dentro del contenido de los documentos mencionados anteriormente. La minería de textos posee muchas aplicaciones, dentro de las cuales se encuentra generar nueva información y conocimiento. La práctica de esta técnica permite a muchas empresas reducir el tiempo invertido en grandes cantidades de texto, lo que en otras palabras quiere decir que encuentra de manera rápida y eficiente los aspectos claves.

Por lo general la minería de texto se puede dividir en cinco pasos, los cuales son los siguientes:

1. **Recolección**
Se recopilan los datos provenientes de diferentes fuentes. Este proceso puede ser automatizado o guiado por una persona.
2. **Preprocesamiento**
Se trata de la identificación de contenido y extracción de factores o características de los datos que son más representativos.
3. **Limpieza de texto**
Este paso elimina información que es innecesaria o que no aporta nada, tal como anuncios de páginas web, entre otros.
4. **Dividir elementos**
La computadora solo percibe cadena de caracteres, los cuales no puede identificar por sí sola, como frases, palabras, oraciones o párrafos. Este paso divide el texto en entidades significativas, tales como palabras, oraciones, párrafos, entre otros, dados por los espacios que separan palabras y signos de puntuación.

4.19.1. Nube de palabras

Se trata de representaciones visuales, en forma de nube, de las palabras que conforman un texto, en el cual mientras mayor sea el tamaño dentro de ella, mayor es la frecuencia de esa palabra dentro del texto analizado. El principal objetivo de las nubes de palabras es facilitar la búsqueda de información al indicar de una manera clara y visual las palabras que más destacan en un texto.

4.19.2. N-gramas

Dentro del ámbito de la lingüística computacional y de probabilidad, se conoce como n-grama a una secuencia de n elementos dado un texto o un discurso. Los elementos dentro de los n-gramas pueden ser sílabas, palabras, letras, oraciones, entre otros, dependiendo de la aplicación que se le quiera dar. Los n-gramas por lo general obtienen sus tokens del cuerpo de textos o discursos.

Cuando los n-gramas son de una sola palabra, son conocidos como unigramas, mientras que si contienen dos elementos, se les conoce como bigramas y de tres elementos como trigramas. Para cuatro elementos o más se utiliza el término de n-grama.

Dentro de sus aplicaciones se encuentra el de predecir el siguiente elemento de una secuencia con orden de $(n - 1)$ en el modelo de Markov. Este modelo es estocástico usado para modelar sistemas que cambian de manera aleatoria. Se asume que los estados futuros son dependientes únicamente de el estado actual en el que se encuentran.

En los n-gramas destaca la cadena de Markov, el cual es el modelo más simple planteado por este autor. Este modela el estado de un sistema con una variable aleatoria que cambia a través del tiempo. En base a este contexto, la propiedad de Markov sugiere que esta variable solo dependa del estado anterior.

4.20. Máquinas de soporte vectorial (SVM)

Si tenemos L puntos de entrenamiento, donde cada entrada x_i tiene D atributos, es decir que tiene dimensionalidad D y está en una de las dos clases $y_i = -1$ o $+1$, indicaría que la información

de entrenamiento es entonces:

$$x_i, y_i \quad \text{donde} \quad i = 1 \dots L, y_i \in \{-1, 1\}, x \in \mathcal{R}^D$$

Aquí se asume que los datos son linealmente separables, es decir se puede trazar una línea en la gráfica de x_1 vs x_2 separando las dos clases cuando $D = 2$ y un hiperplano en las gráficas (x_1, x_2, \dots, x_D) cuando $D > 2$. El hiperplano se puede describir como $\mathbf{w} \bullet \mathbf{x} + b = 0$ donde:

- \mathbf{w} es la normal del hiperplano
- $\frac{b}{\|\mathbf{w}\|}$ es la distancia perpendicular del hiperplano al origen.

Los vectores de soporte son los puntos más cercanos al hiperplano separador. Por lo tanto, el objetivo de las máquinas de soporte vectorial es orientar al hiperplano de manera que se encuentre lo más lejos posible de los puntos más cercanos pertenecientes a las clases clasificadoras.




Figura 4.6: Hiperplano a través de dos clases linealmente separables (Fletcher, 2009)

En la Figura 4.6, implementar SVM se reduce a seleccionar \mathbf{w} y b para que la información de entrenamiento pueda ser descrita por:

$$x_i \bullet \mathbf{w} + b \geq +1 \quad \text{para} \quad y_i = +1$$

$$x_i \bullet \mathbf{w} + b \leq -1 \quad \text{para} \quad y_i = -1$$

Si ahora se consideran los puntos que se encuentran cerca del hiperplano separados, es decir los vectores de soporte (los puntos encerrados en la ilustración), entonces los planos H_1 y H_2 en los que residen estos puntos se puede describir por:

$$x_i \bullet \mathbf{w} + b = +1 \quad \text{para} \quad H_1$$

$$x_i \bullet \mathbf{w} + b = -1 \quad \text{para} \quad H_2$$

Las distancias d_1 y d_2 , son las distancias de H_1 y H_2 al plano respectivamente. La equidistancia entre estos dos planos significa que $d_1 = d_2$ - margen SVM. Para orientar el hiperplano lo más lejano posible de los vectores de soporte requiere que se maximice ese margen. (Fletcher, 2009)

4.20.1. Kernels

El objetivo de un SVM es producir un modelo que predice los valores objetivo de un set de datos, a partir de únicamente los atributos del mismo set. Formalmente, se describe como: dado un set de valores de la forma $(x_i, y_i), i = 1, \dots, l$ donde $x_i \in R^n$ y $y \in \{1, -1\}^l$, el SVM (Boser, Guyon, y Vapnik, 1992) requiere la solución al siguiente problema de optimización:

$$\begin{aligned} \min_{\mathbf{w}, b, \xi} \quad & \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^l \xi_i \\ \text{subject to} \quad & y_i (\mathbf{w}^T \phi(\mathbf{x}_i) + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0. \end{aligned}$$

Los vectores de entrenamiento x_i son mapeados en un espacio dimensional más alto por la función ϕ . SVM busca un hiper-plano separador lineal con el máximo margen en este espacio dimensional. $C > 0$ es el parametro de penalidad en el término de error. Consecuentemente, $K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j)$ se conoce como la función kernel. Cada vez más, nuevas funciones kernel son propuestas por investigadores. Algunas conocidas son los kernel *lineal*, *polinomial*, *función de base radial* (RBF) y *sigmoid* (Chih-Wei Hsu, Chih-Chung Chang y Lin, 2008).

- Linear: $K(x_i, x_j) = x_i^T x_j$
- Polinomial: $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
- Radial Basis Function (RBF): $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$
- Sigmoid: $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

Donde γ , r y d son parámetros de kernel.

En general, el núcleo RBF es una primera opción razonable al momento de implementar este tipo de algoritmo. Este núcleo no lineal mapea muestras en un espacio dimensional más alto, por lo que, a diferencia del núcleo lineal, puede manejar el caso cuando la relación entre las etiquetas de clase y los atributos es no lineal. Además, el núcleo lineal es un caso especial de RBF, ya que el núcleo lineal con un parámetro de penalización C tiene el mismo rendimiento que el núcleo RBF con algunos parámetros (C, γ) . Además, el núcleo sigmoide se comporta como RBF para ciertos parámetros. La segunda razón es el número de hiper-parámetros que influyen en la flexibilidad de la selección del modelo. El núcleo polinomial tiene más hiper-parámetros que el núcleo RBF. Finalmente, el núcleo RBF tiene menos dificultades numéricas. Sin embargo, hay algunas situaciones en las que el núcleo RBF no es adecuado. En particular, cuando el número de características es muy grande, se puede usar el kernel lineal. (Chih-Wei Hsu, Chih-Chung Chang y Lin, 2008)

Hay dos parámetros para un kernel RBF: C y γ . No se sabe de antemano qué C y γ son los mejores para un problema determinado, por lo que se debe realizar algún tipo de selección de modelo. El objetivo es identificar el mejor (C, γ) para que el clasificador pueda predecir con precisión los datos desconocidos (es decir, los datos de las pruebas) (Chih-Wei Hsu, Chih-Chung Chang y Lin, 2008). Se debe de considerar que puede no ser útil para lograr una alta precisión de la formación. Es decir, un clasificador que prediga con precisión los datos de formación cuyas etiquetas de clase son realmente conocidas. Como se mencionó anteriormente, una estrategia común es separar el conjunto de datos en dos partes, una de las cuales se considera desconocida.

4.21. Redes neuronales

Una rama de la inteligencia artificial utilizada especialmente para el análisis de modelos muy complejos con muchas variables es la red neuronal. Una red neuronal en el ámbito de la computación es una colección de unidades computacionales con características específicas para cumplir con un propósito. Una red neuronal se compone por unidades llamadas neuronas conectadas por un enlace, es decir la salida de una es la entrada de otra agregando cierto peso arbitrario, agrupadas en capas. Por medio de este enlace se activan las neuronas consecuentes y se nota la influencia que mantiene en la red neuronal. Cada neurona, “adentro” de ella computa las entradas con su peso haciendo una sumatoria y esto se le aplica la función de activación que finalmente envía su resultado hacia la salida. (Russell, S., & Norvig, 2009)

Las funciones de activación suman de la entrada con pesos y con ella se obtiene una respuesta que será llevada las neuronas de la próxima capa. Las neuronas en una misma capa utilizan el mismo tipo de función de activación. Existen funciones de activación lineales y no lineales, las no lineales son utilizadas en redes neuronales con varias capas (deep neural network). (Sivanandam, S., Sumathi, S., & Deepa, 2017) La función de activación Sigmoid, que convierte las variables en probabilidades entre 0 y 1, fue muy utilizada pero actualmente la función Rectified Linear o ReLu es la más utilizada pues ha demostrado funcionar mejor en práctica y permite un mejor entrenamiento que Sigmoid además resolvió algunos problemas que se enfrentaban con Sigmoid o variaciones de la misma. (Patterson, J., & Gibson, 2017)

La función de activación Concatenated ReLu (CReLu) es una variación de la función ReLu utilizada inicialmente para redes neuronales de convolución, una operación binaria entre funciones, pero demostró ser eficiente también para otro tipo de redes. La definición de CReLu es una concatenación de una ReLu simple y de una ReLu negativa, de esta forma la salida se duplica pues se obtiene una respuesta de cada función ReLu separada. (Shang, W., Sohn, K., Almeida, D., & Lee, 2016)

Overfitting es un fenómeno de los modelos de redes neuronales donde dicha red se “sobre entrena” con los datos de entrenamiento por lo que su porcentaje de confiabilidad solo es con los datos entrenamiento y no da un bien porcentaje en la vida real. (Benjamin, 2014)

Una herramienta para reducir el overfitting es la técnica llamada “Dropout”. Su función es forzar la red neuronal a distribuir la representación aprendida del modelo en todas sus neuronas. Esta técnica se basa en la desactivación aleatoria de ciertas neuronas en las capas durante el entrenamiento. Esta desactivación llamada dropout es aleatoria por cada computación de entrenamiento. Basando en este se coloca cierta probabilidad de que la neurona este desactivada. (Hope, T., Resheff, Y., & Lieder, 2017) El efecto principal que se desea lograr con esta técnica es implementar la regularización de la red dentro del procedimiento de enseñanza. Incorpora ruido en ambos tipos de neuronas: de entrada y escondidas. El agregar ruido a una red neuronal actúa como un regularizador. Y esta técnica trabaja para normalizar mejor que otras utilizadas. Sin embargo, por ser una técnica de regularización reduce el poder expresivo que podría tener una red por lo que solo se debería de utilizar en modelos muy grandes para tomar ventaja de este método. (Aggarwal, 2018)

Una Deep Neural Network o DNN Es una red neuronal artificial de propagación. La diferencia principal contra una red neuronal normal es la presencia de más de una capa escondida de neuronas, El término “capa escondida” o “capa oculta” se refiere a que no es la capa de entrada o la de salida. Una DNN con altas cantidades de capas y neuronas crean modelos muy flexibles que permiten manejar muchas variables. También permite modelar relaciones muy complejas y no lineales entre los datos entrantes y las decisiones salientes. (Hinton, G., Deng, L., Yu, D., Dahl, G., Mohamed, A., & Jaitly, 2012)

El Multilayer Perceptron o MLP es un tipo de red neuronal profunda o DNN. Un MLP cumple con las siguientes tres características: tiene un o mas capas escondidas, lo que lo hace una DNN; emplea una función de activación no lineal y tiene un grado alto de conectividad, se puede considerar

así cuando todas las neuronas de una capa tienen conexión a las de la siguiente. Estas características le permiten a un MLP a manejar modelos muy complejos obteniendo características importantes de los datos de entrada. (Bow, 2002)

Una red neuronal probabilística es una implementación estándar de una arquitectura de red prealimentada, utilizando tres capas prealimentadas para calcular funciones de densidad probabilística para las clases encontradas en los datos de entrenamiento. Este tipo de red provee la probabilidad y confianza para las clasificaciones resultantes. (Byrnes, Hargreaves, y Berry, 2012)

4.22. Redes neuronales convoluciones

Las redes neuronales convoluciones son utilizadas en modelos de aprendizaje profundo en el campo de visión artificial, que son métodos utilizados para poder procesar y analizar imágenes, para obtener información cuantitativa de esta. Se intenta producir el mismo efecto que poseen los humanos para poder percibir y comprender las imágenes. Se utilizan convoluciones a través de los datos, estas operaciones convoluciones permiten que la red sea capaz de detectar bordes, y características complejas de los datos. Esta es utilizada en combinación con capas de agrupación (pooling). Para reducir el número de parámetros se pueden utilizar métodos para compartir pesos, con esto se pueden encontrar características dentro de una imagen. Al compartir los pesos se pueden identificar patrones. Esto se puede lograr a través de capas de convolución, con esto también se logra conectividad local. Mediante la agrupación se puede reducir el número de activaciones que se producen en la capa de convolución, esto es importante, puesto que las capas de convolución llegan a producir activaciones que son insignificantes. Al combinar las capas de convolución y de agrupación, se crean una nueva capa que es utilizada por las redes neuronales convoluciones utilizadas en la inteligencia artificial. Mediante la representación de las capas de convolución y agrupación, se puede representar a los datos en pedazos más pequeños de imagen, con esto se pueden identificar objetos presentes en la imagen. En las redes convoluciones usualmente la primera capa que se aplica es la de convolución, esta es la que permite obtener características de una imagen. En ella se mantiene la relación entre píxeles, aprendiendo características de la imagen, utilizando pequeños cuadros de datos. En el caso de tener una imagen de dimensión de 5×5 , y al aplicarle una función convoluciones sobre una matriz de 3×3 , entonces se aplican sobre los primeros 3×3 datos, aplicando cierta función que da como salida un nuevo número, esta función aplicada puede determinar la búsqueda de bordes, líneas o figuras dentro de la sección a la cual se está aplicando la función. (Venkatesan, 2018)

4.23. K vecinos más cercanos

El algoritmo de k vecinos más cercanos es uno de los métodos fundamentales de clasificación y suele ser utilizado cuando hay poco o ningún conocimiento de la distribución de los datos. El objetivo principal de este algoritmo es satisfacer con la realización de un análisis discriminante para las estimaciones paramétricas fiables de la densidad de probabilidad para los datos con las características anteriormente descritas.

Se basa en el cálculo de distancias euclidianas para la generación de un modelo predictivo. Aunque otras técnicas pueden utilizarse, la distancia euclídeana por lo general brinda eficiencia y productividad algorítmica. De esta forma, un dato de muestra puede clasificarse a partir de la mayoría de las etiquetas que tengan sus k vecinos más cercanos.

Si una muestra 'x' tiene k ejemplos más cercanos, donde en el espacio de la característica la mayoría de estos tienen la misma etiqueta 'y', entonces 'x' pertenece a 'y'. Una de las principales desventajas de este algoritmo es su ineficiencia para conjuntos de datos a gran escala y de alta dimensión. La razón principal de este inconveniente es su naturaleza de algoritmo de aprendizaje

'perezoso' y es que no tiene una verdadera fase de aprendizaje. Esto supone un alto coste computacional a la hora de la clasificación de la clase. (Kataria y Singh, 2013) Existen varias maneras de calcular la distancia entre dos puntos, en este documento se presentará la metodología euclidiana y la metodología manhattan.

Distancia euclidiana

Se trata de una consecuencia del teorema de Pitágoras. La distancia euclidiana entre dos puntos 'p' y 'q' es el largo de la línea que los conecta en el plano cartesiano. Si $p = (p_1, p_2, \dots, p_n)$ y $q = (q_1, q_2, \dots, q_n)$ son dos puntos en un espacio euclidiano entonces la distancia se define por la fórmula que se encuentra en la Figura 4.7.

$$d(p, q) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2}$$

Figura 4.7: Cálculo de la distancia euclidiana

Distancia manhattan

Dice que la distancia entre dos puntos es la suma de las diferencias absolutas de sus coordenadas. La suma de las longitudes de los dos catetos de un triángulo rectángulo. En la figura 4.8 se encuentra la fórmula general para este caso.

$$d(p, q) = \sum_i^n |p_i - q_i|$$

Figura 4.8: Cálculo de la distancia manhattan

4.24. KNIME

KNIME es una plataforma modular de exploración de datos que permite al usuario crear flujos de información de manera visual por medio de utilidades llamados nodos, los cuales pueden ser ejecutados uno a uno o ejecutarlos en cadena. Provee nodos para tareas comunes de exploración y manejo de información, pero también incluye nodos de algoritmos de aprendizaje de máquina con los que se puede experimentar rápidamente. (Berthold, Borgelt, Höppner, y Klawonn, 2010)

4.25. Python

Python es un lenguaje de programación interpretado cuya filosofía se centra en código legible. Es un lenguaje multiparadigma, que soporta programación orientada a objetos, programación imperativa y en menor medida programación funcional. (Kuhlman, 2012)

4.26. MongoDB

MongoDB es una base de datos de propósito general orientada a documentos, separándose así del diseño relacional tradicional. Los documentos reemplazan el concepto de fila, siendo una solución más flexible, permitiendo la inserción de documentos jerárquicos complejos. (Chodorow, 2013)

4.27. Flask

Flask es un ambiente de trabajo para desarrollo web con una filosofía minimalista. A pesar de ser un ambiente de trabajo pequeño su arquitectura extensible le permite adaptarse a muchos casos de uso. Flask tiene dos dependencias principales: Werkzeug que brinda el servidor web y Jinja2 que brinda el sistema de plantillas HTML. Flask y sus dependencias principales fueron todas desarrolladas por Armin Ronacher. (Grinberg, 2018)

4.28. VueJS

VueJS es un ambiente de trabajo para el desarrollo de interfaces de usuario web que utiliza modelos de datos como base para el renderizado de componentes visuales. (Filipova, 2016)

4.29. Socket.IO

Socket.IO es una librería utilizada para la comunicación en tiempo real principalmente en ambientes web. Abstrae la complejidad de los sockets brindando una interfaz basada en eventos. (Rai, 2013)

4.30. pyAudio

pyAudio es una librería de Python que permite utilizar las funciones de la librería multiplataforma PortAudio, la cual provee una interfaz sencilla para grabar o reproducir audios a micrófonos o bocinas. (Pham, 2006)

4.31. OpenCV

OpenCV es una librería de Python que permite la manipulación de imágenes y el procesamiento de videos. También tiene una sección de machine learning utilizada para la detección de puntos en el rostro. (O. Team, 2018)

4.32. Scikit-learn

Provee un ambiente con implementaciones de algoritmos de aprendizaje de máquina, manteniendo una interfaz sencilla de utilizar que se integra sin dificultad al intérprete Python. Simplifica el

proceso de análisis de información para los “inexpertos”, es decir los desarrolladores que no se han dedicado a esta área específicamente. Esta librería no tienen más de dos dependencias, que exhorta a desarrolladores a programar y no a pensar en un flujo de marcos de trabajo, al mismo tiempo el hecho de que esta librería exista al alcance de otros ha permitido la optimización de sus implementaciones en términos computacionales, como lo es la implementación de SVM que ahorra 40 % de memoria. (Weiss, 2012)

4.33. Dlib

Dlib es un conjunto de herramientas modernas construido en el lenguaje de C++, que contiene algoritmos de aprendizaje automático y herramientas para poder crear software complejo en C++ y resolver problemas del mundo real. Se usa en la industria como en el mundo académico en una amplia gama de dominios tales como robótica, teléfonos móviles y entornos informáticos de alto rendimiento. Su licencia es de código abierto, porque se permite utilizarlo en cualquier aplicación. Entre sus características principales, se encuentra el procesamiento de imágenes, dentro de esta rama se encuentran herramientas para poder hacer las siguientes tareas: Rutinas para poder leer y escribir imágenes en los formatos más comunes, operaciones comunes de imágenes para poder encontrar esquinas y operaciones morfológicas, implementación de algoritmos de extracción de información, herramientas para poder detectar objetos dentro de las imágenes, que incluyen tareas como la detección frontal de rostro y reconocimiento facial de alta calidad. Dlib es una librería principal del lenguaje de programación C++, a pesar de ello se puede utilizar un gran número de sus herramientas en aplicaciones construidas en el lenguaje de programación Python. (Dlib, 2018)

5.1. Estudio de detección del engaño

Paul Ekman hizo una serie de estudios entre culturas en los años 60's enfocándose en expresiones faciales, emociones y gestos. También estudió el engaño. En 1991, Ekman investigó la habilidad de identificar mentiras de individuos de diferentes profesiones. Se centró específicamente, en aquellas que estaban expuestas al engaño, como policías, psiquiatras, jueces, y un grupo control que eran estudiantes universitarios. Ekman encontró que los que mejor tenían esta habilidad eran agentes del servicio secreto, quienes debían apoyarse en sus habilidades de reconocer expresiones no verbales. También pudo correlacionar edad, concluyendo que esta habilidad era mejor en personas menores de 40 años. Sin embargo, otros estudios como el de Kohnken demostraron resultados opuestos, diciendo que son las personas mayores y con más experiencia quienes pueden detectar mejor el engaño (Vicianova, 2015)

Según Ekman, muchos de los estudios de detección de mentiras fracasan en sus experimentos ya que siempre se realizan de la misma forma: A un grupo de estudiantes se les pide que mientan y que digan la verdad sobre algo que, en general, no les importa mucho y luego otro grupo de estudiantes analiza las grabaciones. Generalmente, estos estudiantes rinden al nivel del azar o muy poco por encima de él. Otra limitación que hace que las personas fallen en detectar mentiras es que los investigadores/observadores no se ganan la vida ni obtienen algo muy gratificante al detectar las mismas (Vicianova, 2015).

Ekman también argumenta que hay más probabilidades de tener éxito en los estudios en los que se procura que las mentiras guarden relación con la vida de los participantes y que para ellos sea importante el éxito o el fracaso de la detección de las mismas. Esto se debe a que los participantes probablemente estarán sintiendo culpa, vergüenza, temor, entusiasmo y otras emociones asociadas a mentir. Estas emociones son fuertes y difíciles de ocultar. También pueden alterar las funciones cognitivas de quien miente y hacerlo generar explicaciones poco convincentes. Otro factor que podría ayudar a elevar el porcentaje de éxito es darles la opción a las personas de decir la verdad o la mentira al principio, ya que de esta forma se pueden identificar a las personas que son malas mentirosas. También decir que quienes no logren convencer al investigador de qué está diciendo la verdad serán castigados (Ekman, 2014).

En otro estudio, se le pidió a un grupo de 73 estudiantes el mentir en una situación donde no contaban con tiempo para preparar la mentira, es decir, se requería un esfuerzo cognitivo de parte

de ellos. Los estudiantes mostraron señales conductuales a causa de la sobrecarga cognitiva como: desviación de contacto ocular, movimiento de manos, dedos, piernas y pies, pausas llenas, alteración del habla y del periodo de latencia. Codificadores entrenados fueron quienes registraron las variables verbales, no verbales indicadoras de sobrecarga cognitiva. Si se entrena a los sujetos es posible lograr que discriminen entre declaraciones verdaderas y falsas a partir de conductas no-verbales (Vrij, 2000).

5.2. Relación entre psicopatía e inteligencia emocional

Un estudio realizado por Copestake *et al.* (2013) exploró la relación entre un componente de psicopatía con la capacidad de inteligencia emocional. La investigación se realizó con una muestra de población penitenciaria. Entre las pruebas utilizadas en el estudio se incluyó la Escala de Psicopatía Revisada (PCL-R) y el Test de Inteligencia Emocional Mayer-Salovey-Caruso. Los resultados comprobaron pocas correlaciones entre los resultados de una prueba y otra, con poca significación estadística. La mayor significación se encontró en el componente antisocial de la prueba de psicopatía con el de percepción emocional de la prueba de inteligencia emocional (Copestake, 2013).

5.3. PCL-R en otras poblaciones

La escala de psicopatía diseñada por Robert Hare en 1980 (PCL) y su versión revisada en 1991 (PCL-R) fueron utilizadas para la evaluación de psicopatía en poblaciones penitenciarias en base a rasgos conductuales y de la personalidad usualmente asociados con el desorden. Posteriormente, en 1996, se diseñó una versión de detección de la escala de psicopatía (PCL-SV), fue diseñada para ser aplicada en poblaciones no forenses y utilizada con fines de identificar sujetos candidatos a un posible diagnóstico de psicopatía. En 1996 por medio de una investigación con población universitaria, se comprobó la fiabilidad del instrumento al aplicarse a tanto hombres como mujeres dentro de un contexto no forense (Forth, 1996).

5.4. Detección de microexpresiones

En un estudio de detección de microexpresiones, se recogieron datos por medio de video, luego se detectó el rostro en la imagen y se realizó una extracción de características donde se resaltan atributos clave para la identificación de las emociones (ojos, boca, cejas, nariz). Luego, las expresiones se clasifican comparándolas con imágenes existentes en la base de datos. Para esta clasificación se utilizaron las técnicas de reconocimiento: Eingefaces y Fisherfaces, que toman como referencia el funcionamiento del cerebro con respecto a la identificación de rostros. Eingefaces se basa en el análisis de componentes principales. Esta fue la herramienta que dio mejores resultados en cuanto a eficacia y eficiencia, con un 2.7% de error. A través del estudio de los algoritmos fue posible identificar si la velocidad de procesamiento influye en la calidad de los resultados (Gutierrez, 2017).

En otra investigación se concluyó que no hay relación entre la posición de la mirada y decir mentiras. Se realizaron tres distintos experimentos donde se les pedía a las personas realizar una acción por su cuenta y luego en una habitación aparte se les entrevistaba. En uno de los experimentos se les pedía que subieran a una oficina y guardaran un celular en un escritorio. Luego en la entrevista se les cuestionaba que vieron en el escritorio y en las gavetas, ante lo cual obtuvieron respuestas normales. El segundo experimento constaba en mostrar 32 videos de gente diciendo cosas y luego se les pedía a las personas que indicaran cuáles de las personas en los videos estaban diciendo la verdad o estaba mintiendo. Según los resultados la media de respuestas correctas fue de 16.33 mientras que la confianza en sus respuestas fue de 4.65. El tercer experimento fue similar al segundo, pero

variando el largo de los videos. En según estos resultados concluyeron que no existía la relación (Wiseman, 2012). El estudio de Davidson *et al.* (2016) presenta algunos antecedentes de técnicas de distribución de regiones faciales para la detección de microexpresiones: • Primero, la división del rostro en cuatro cuadrantes para el análisis de cada uno de estos por sus secuencias temporales. Esta técnica cuenta con la desventaja de recopilar información restringida a áreas del rostro donde se involucró un movimiento global. • También se ha explorado la división del rostro en bloques específicos, lo cual cuenta con la ventaja de analizar pequeños cambios en bloques temporales, en contraste a un movimiento global, sin embargo, este método cuenta con la desventaja de ser costoso de programar y de abarcar áreas del rostro de poca relevancia para el significado del movimiento. • Por otra parte, se ha intentado utilizar la triangulación de Delaunay para formar regiones del rostro que excluyan debidamente elementos como el cabello y el cuello del vector de movimiento. Al igual que el uso de bloques, esta técnica cuenta con la desventaja de ser computacionalmente costosa, además de presentar regiones de poca utilidad. • Adicionalmente, se ha estudiado de forma reciente la utilización de regiones de interés definidas (ROI) las cuales se enfocan en áreas locales de la cara que se mueven debido a activación muscular. Por parte del autor Matthew Shreve, se presenta una técnica que se basa en segmentar fotogramas de macro y micro expresiones capturadas en video por medio de calcular la tensión muscular dentro de un campo de flujo óptico correspondiente a la deformación elástica del tejido de la piel. El proceso conlleva: • La extracción de las macro expresiones por medio del algoritmo de expresiones faciales • Observar que la magnitud de estiramiento sea más larga que en las regiones cercanas mientras que la duración de • Observar que el estiramiento no debe durar más de un quinto de segundo. (Davison, 2016)

5.5. Uso de emotiv

Existen muchos métodos que han probado ser efectivos para detectar la actividad eléctrica del cerebro mientras una persona miente, principalmente los que miden Potenciales Relacionados a Eventos (PEV). Estos miden la capacidad de evocación y alteración de los procesos cognitivos al dar información falsa. Sin embargo, estos han mostrado tener limitaciones en cuanto a diseño del experimento. Además, de acuerdo a un estudio realizado en 2014, se puede trabajar la detección de mentiras por medio de un registro de actividad electroencefalográfica con por lo menos dos electrodos de la onda P300. Esta mide el reconocimiento de una persona a un estímulo, que evoca una amplitud de onda involuntaria. Los potenciales evocados no pueden ser manipulados por la persona. Para evaluar si el comportamiento de la onda es diferente durante el proceso de engaño, se hace una comparación de medias de las amplitudes de las ondas (Camargo, s.f.).

El estudio de Camargo, Urrea y Mongui (2016) utilizó los resultados de patrones de actividad cerebral del equipo Emotiv Epoc como indicador de engaño, utilizando una muestra de estudiantes universitarios. Durante el estudio registraron señales eléctricas del cerebro en las áreas prefrontal dorsolateral, prefrontal medial y orbito frontal, justificándose en su relación con tareas ejecutivas. Los resultados del estudio demostraron que el comportamiento de la señal eléctrica en el momento de engaño fue diferente en cuanto a voltaje y organización de curvas en comparación al momento sin engaño, el estudio recomendó analizar las diferencias estadísticas entre las condiciones por medio de estadísticos inferenciales como uso de una Anova funcional o modelos lineales generalizados. Al hablar de los electrodos, los resultados mostraron mayor activación al momento del engaño en los siguientes electrodos: AF3 y AF4, que miden la actividad en la corteza prefrontal; FC5,FC6 y F8, que miden la actividad en las áreas de Brodman 44 y 45 (encargadas de la expresión verbal) ; F3 y F4, que miden la actividad en el área motora suplementaria (expresión no verbal). En el electrodo F7 hubo mucha variabilidad en los datos (Camargo, s.f.)

5.6. Tiempos de reacción

Una forma de medir la actividad cognitiva del engaño es estudiando los tiempos de reacción. Durante las últimas décadas, con los avances de la tecnología, medir los tiempos de reacción se ha vuelto cada vez más fácil, por lo que ha crecido el interés por estudiar este fenómeno. Luego de hacer una revisión de 114 estudios de tiempos de reacción, Suchotzki *et al* concluyen lo siguiente: Los resultados han sido mixtos: en algunos estudios se han encontrado diferencias, pero muy poco significativas. Una posible razón para estos resultados tan desfavorables es que los tiempos se estén midiendo en condiciones poco adecuadas. Otros factores que pueden influir son: falta de publicación de estudios, la velocidad en que se dan las instrucciones, la velocidad en la que se presentan los estímulos, el tipo de paradigma, el número de ensayos, y el nivel de motivación para mentir. Varios autores han argumentado que para medir tiempos de reacción significativos se debe cumplir con ciertos criterios: tiene que ser preciso (i.e. computarizado), los participantes deben poder contestar inmediatamente y se les debe decir que contesten lo más rápido posible, y los tiempos deben ser promediados sobre varias medidas, por lo menos 20 medidas por sujeto. Los efectos de los tiempos de reacción no solo se deben a procesos cognitivos, sino también a la carga emotiva que conlleva el experimento, no solo por el tipo de estímulos presentados, sino por el hecho de tener que mentir. (Suchotzki, s.f.).

El alcance de este megaproyecto es la definición, diseño, creación y producción de una herramienta que incorporará varias técnicas para la estimación de probabilidad del engaño utilizando diversas herramientas como grabación de voz, detección de microexpresiones y grabación de señales electroencefalográficas. Diferenciándose cada acercamiento con el algoritmos o tipo análisis de datos enriqueciendo la investigación. El proyecto no pretende detectar en sí el engaño, sino estudiar las variables que influyen a la hora de elaborar el engaño con el fin de crear un sistema que estime una probabilidad de presencia de engaño.

7.1. Recopilación de datos

7.1.1. Convocatoria y formulario sociodemográfico

La primera fase para recopilar datos fue la convocatoria de miembros de la Comunidad UVG. Esta se realizó por medio del correo electrónico de la facultad de ingeniería y el departamento de Psicología y a través de la técnica de bola de nieve. Al haber convocado a las personas, primero se les pasó un consentimiento informado, velando por la confidencialidad de las personas y tomando en cuenta el valor de la ética de la UVG. Luego, se les pidió que contestaran un cuestionario sociodemográfico con datos como: sexo, edad, sector de la UVG al que pertenece, nivel académico, lateralidad, si trabaja o no, y si había asistido a algún servicio psicológico en su vida.

7.1.2. Entrevistas

Al diseñar el experimento, se decidió utilizar una entrevista basada en el paradigma del Test de Mentira de Sheffield (Suchotzki, s.f.), en el que se hace una serie de preguntas en las que se les pide que digan la verdad y otra en las que se les pide que mientan, y usualmente son las mismas preguntas. Las entrevistas tenían entre 16 y 17 preguntas cada una dependiendo de lo que respondía la persona. Estaban compuestas por dos tipos de preguntas: abiertas y cerradas. Las preguntas cerradas son aquellas donde las respuestas están limitadas a una pequeña selección y usualmente son 'sí' o 'no'. Las preguntas abiertas son aquellas donde las respuestas varían ya sea en tamaño o estructura. En ocasiones las preguntas tenían continuidad y se mezclaba entre una cerrada y una abierta, ya que en la segunda pregunta se les pedía que elaboraran la respuesta de la primera pregunta. El orden de las entrevistas variaba por persona, pero la mayoría empezaba con la entrevista donde tenían que responder únicamente con la verdad. Para la prueba del sistema se diseñó una entrevista diferente, en la que primero se les pedía a los participantes que contestaran de forma sincera y luego se les planteaba una situación hipotética, que podía o no aplicar a sus vidas. En el caso de que no aplicara, se les pedía que mintieran. Después de la entrevista se les preguntó en cuáles preguntas mintieron

para contrastar las respuestas. Ambas entrevistas se encuentran en la sección de anexos.

7.1.3. Pruebas psicométricas

Para medir ciertas capacidades y rasgos de la muestra, con el fin de evaluar su efecto sobre las manifestaciones de engaño, se utilizaron las siguientes pruebas psicométricas:

- Test de Inteligencia Emocional MSCEIT, de D. R. Caruso, J.D. Mayer y P. Salovey (1999), que evalúa la inteligencia emocional, entendida como una capacidad, en cuatro dimensiones: percepción, facilitación, comprensión y manejo emocional. El tiempo de aplicación de esta prueba es de entre 30 y 45 minutos. La misma fue digitalizada para facilitar la recopilación de datos. Este test está basado en el modelo de habilidad de Salovey y Mayer. El test brinda un índice de inteligencia emocional global (CIE). Además divide este resultado dando a conocer la capacidad del evaluado en cuanto a su propia experiencia emocional (CIEEX) y en cuanto a su desempeño en el ámbito social (CIES). Salovey y Mayer dividen la inteligencia emocional en cuatro habilidades, por lo que la prueba da cuatro índices adicionales: percepción emocional (CIEP), facilitación emocional (CIEF), comprensión emocional (CIEC), regulación emocional (CIEM).
- El Test de Símbolos y Dígitos SDMT (1982), de Aaron Smith, que evalúa velocidad de procesamiento. El tiempo de aplicación de esta prueba es de aproximadamente 10 minutos. La prueba consiste en convertir símbolos con forma de figuras geométricas en números a partir de una clave establecida, en la que por cada símbolo hay un dígito correspondiente.
- Tarea de DigitSpan para evaluar memoria de trabajo y atención diseñada en el programa PEBL. La aplicación de esta toma aproximadamente 15 minutos. La tarea consiste en observar una serie de números en la pantalla y reproducirlos en el orden que corresponde en la siguiente pantalla. Los resultados muestran un valor general, que representa el nivel de retención de información y dan el tiempo total que le tomó a la persona llevar a cabo la tarea.
- la Escala de Evaluación de Psicopatía Hare (1991), de Robert D. Hare, es un instrumento utilizado tanto para la población penitenciaria como en el ámbito clínico y forense. La prueba cuenta con 20 preguntas que se valoran en una escala de 0, 1 o 2 puntos de acuerdo a diferentes características para proporcionar una puntuación general de psicopatía. Es una prueba útil para detectar perfiles delictivos y conductas antisociales. Su aplicación toma alrededor de 15 minutos. Esta da una puntuación general que representa el grado en que la persona muestra un rasgo psicópata de personalidad. Dentro de las características que evalúa la prueba se encuentran la ausencia de autocontrol, ausencia de empatía, la superficialidad emocional, la manipulación, la falta de aceptación de consecuencias por conducta y la mentira patológica. Todas estas características pueden influir en la capacidad de un sujeto para mentir.

7.2. Población y muestra

La muestra incluye 54 miembros de la comunidad UVG (N=54). Se determinó como factor excluyente que los participantes no tengan patologías o daños cerebrales. Además, que el sexo y la escolaridad no son variables relevantes, por lo que estos no están especificados en el perfil. El rango de edad que se definió es de 18 a 50 años, con el fin de evaluar personas de distintos sectores de la población UVG. Se decidió que el tipo de muestreo sería probabilístico aleatorio simple. Los resultados del cuestionario sociodemográfico muestran la siguiente distribución: Hay un total de 29 mujeres (53%) y 25 hombres (47%); el entrevistado más joven tenía 18 años al momento de ser entrevistado y el más grande de edad tenía 38, con una media de 21 años; 46 (87%) de los

participantes tienen lateralidad derecha, mientras que 8 escriben con la mano izquierda (13%); 15 (28%) afirmaron que trabajan, mientras que 39 (72%) de ellos no trabajan; la mayoría, un 53% (29 participantes) tiene nivel educativo de diversificado; y un 44% (24 participantes) ha tenido algún tipo de acompañamiento psicológico a lo largo de su vida.

7.3. Análisis estadísticos

El análisis estadístico realizado para medir el efecto de las medidas psicométricas en las manifestaciones del engaño fue realizado en el programa SPSS v22. Este análisis se puede dividir en varias fases: En primer lugar, se realizó un análisis descriptivo de los resultados de las pruebas para conocer los resultados generales de la muestra. Posteriormente, se trabajó con los resultados de las entrevistas, dividiendo los mismos en tres bases de datos para probar las distintas hipótesis planteadas. Con todas las bases se probó la normalidad de los datos con un análisis de Shapiro Wilk, para definir los análisis estadísticos a utilizar. Finalmente, se realizó un análisis de correlaciones, ya sea de Spearman o Pearson, para las tres bases y un análisis de MANOVAs para analizar el efecto del nivel desempeño en las diferentes pruebas psicométricas al momento del engaño.

7.4. Detección de parpadeos y posición de los ojos

El enfoque principal de este estudio es el seguimiento de los ojos. Sin embargo, durante el análisis también se tomó en cuenta un comportamiento más del ojo: el parpadeo. Según la investigación de Soukupova T. y Cech J, el parpadeo en tiempo real se detecta con la siguiente ecuación:

$$EAR = \frac{||p2 - p6|| + ||p3 - p5||}{2||p1 - p4||}$$

Básicamente en la ecuación el numerador calcula la distancia vertical de los puntos de los ojos y el denominador calcula distancia horizontal.

Los parámetros que se le ingresaron a la ecuación fueron las coordenadas de los puntos de los ojos. Donde p2 son los puntos 38 en el ojo derecho y 44 en el ojo izquierdo; p6 son 42 y 48; p3 son 39 y 45; p5 son 41 y 47; p1 son 37 y 43; p4 son 40 y 46. Se calcula dos veces este valor una para cada ojo y se obtiene un valor promedio. De esta manera si la persona guiña un ojo, este no se toma como un parpadeo. Cuando la persona parpadea el valor de la ecuación se acerca a 0, de lo contrario se mantiene en un rango de 0.28-0.32 dependiendo el tamaño del ojo. Para la detección de parpadeo entonces se estableció un límite de 0.27 para ser comparado con el valor final del promedio. Entonces si el valor del promedio baja de 0.27 se tomó como un parpadeo. Gracias al análisis de los vídeos, se determinó que un parpadeo puede ser tan corto de ocurrir en al menos 3 fotogramas. Por lo tanto, se estableció un mínimo de fotogramas donde si el promedio bajaba de .27 por más de tres fotogramas se consideraba un parpadeo. De esta manera se obtuvo la cantidad de parpadeos. Se aplicó la siguiente fórmula para obtener el segundo donde ocurría el parpadeo:

$$s = \frac{n}{30}$$

Donde s es el segundo y n es el número de fotograma. El resultado se redondeó a un entero y de

esta forma se obtuvo el segundo en el que ocurría algún parpadeo. Luego, para encontrar la posición de los ojos se utilizaron los mismos puntos de los ojos. Pero a estos se puntos descritos en el siguiente diagrama.




Figura 7.1: diagrama de puntos detectores de intensidad de píxeles

Se colocaron 11 puntos dentro del ojo. Para obtener los puntos del centro calcularon los puntos intermedios. Luego se les dio un pequeño desfase para que todos quedaran dentro del ojo. Con la misma librería, CV2, se tomaron muestras de los colores que tenían debajo esos píxeles donde quedaban los puntos. En un principio se estaba manejando un arreglo RGB para los puntos, pero lo mejor fue ponerle un filtro al vídeo. El filtro lo que hace es que convierte todo el vídeo en blanco y negro. Entonces con los mismos métodos este ya no regresaba un arreglo RGB, pero únicamente un valor entero de intensidad. En las partes donde era más oscuro, el valor se acerca a 200 y lugares más claros los valores están por debajo de 184. Entonces estos 11 puntos sirven como sensores de color. Dependiendo de la intensidad que detecten, indican si hay algo oscuro debajo de ellos. Por ejemplo, si los puntos 1, 2, 5 y 6 detectan que hay más intensidad sobre ellos que el resto de los puntos entonces la persona esta viendo en diagonal hacia arriba a su derecha. De esta manera se supo a donde estaba viendo la persona en todo momento. Se juntaron ambos los parpadeos y los cambios de dirección de ojos que ocurren en cada respuesta a una pregunta y se guardaron los resultados en un archivo CSV.

7.5. Preparación de datos

7.5.1. Voz

Procesamiento de archivos de audio

A partir de los archivos de audio de las entrevistas completas se realizó un recorte de segmentos de audio más pequeños que inician desde el momento en el que el entrevistador finaliza la pregunta hasta que el entrevistado termina de responder. Dada la estructura de la entrevista se conocía cuáles segmentos de audio correspondían a gente diciendo la verdad y cuáles a gente mintiendo, con lo que se etiquetó cada archivo de segmento de respuesta recortado como (verdad) o (mentira).

Extracción de variables desde archivos de audio

Utilizando el Script de automatización del anexo B, se convirtieron todos los archivos de audio a archivos en formato WAV, necesario para utilizar la herramienta SoX, con la que se extrajeron las variables DC Offset, Min level, Max level, Pk lev dB, RMS lev dB, RMS Pk dB, RMS Tr dB, Crest factor, Flat factor, Pk count, Bit-depth, Num samples, Length s, Scale max y Window s a partir de los segmentos de audio. La información resultante fue almacenada en una base de datos de MongoDB, utilizando la estructura del anexo C.

7.5.2. Transformada de Fourier

Para obtener la frecuencia de la voz con la que los entrevistados hablaron, se utilizó la transformada rápida de fourier o “Fast Fourier Transform”, la cual es equivalente a la transformada discreta de Fourier. Para realizar esta tarea se utilizó la librería de numpy, la cual integra ya dentro de sus funciones la transformada rápida de fourier y para convertir los datos a Hertz.

El algoritmo básicamente recibe un archivo de audio y de éste se sacan el tamaño de los datos, los canales que tiene, entre otros. Posteriormente estos datos se traslada a un arreglo de numpy y a esta misma variable se le saca la transformada rápida de Fourier. La transformada rápida de Fourier devuelve un arreglo que contiene números imaginarios, a la cual se le tiene que sacar la magnitud, pero este problema lo resuelve también numpy ya que dentro de su librería contiene la función de sacar las frecuencias del resultado de la transformada rápida de Fourier. Finalmente se tomó la frecuencia más representativa de cada archivo.

Al iterar sobre cada archivo de verdad y mentira que se tenía disponible de cada participante, se procedió a añadir esta variable al archivo csv que recopila todos los datos, para su posterior análisis exploratorio00.

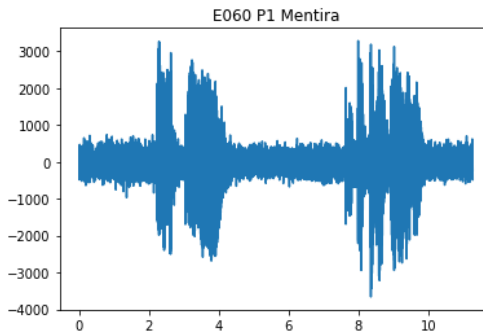


Figura 7.2: Gráfica de señal de audio.

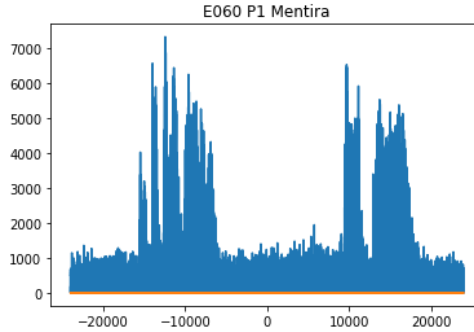


Figura 7.3: Gráfica de audio en dominio de frecuencia.

7.5.3. Señales electroencefalográficas

Primero se construyó un programa para interpretar las lecturas provistas por la herramienta Emotiv EPOC+, el cual permitía lecturas de bloques de información de 10 segundos. Por lo que se tuvo que manualmente, con apoyo de los módulos de voz y audio, conseguir los segundos de importancia y relevancia a ser analizados. Estos tiempos de importancia consistían principalmente en el tiempo que la persona comenzaba a formular su respuesta y al responder.

Con los datos extraídos de los participantes se construyó una base de datos con la estructura que se puede ver en la Figura D.1 que almacenó todas las mediciones conjuntamente con las características que llegarán a ser importantes para el perfil del participante: sexo, edad, escolaridad, lateralidad y los resultados de exámenes psicométricos.

7.5.4. Microexpresiones

Se grabaron 102 vídeos de los cuales se retiraron 4 vídeos o 2 entrevistas completas debido a que hubo algún error con la grabación y estos solamente duraban 1 segundo. El tiempo total de los 98 vídeos eran de 3 horas, 37 minutos y 12 segundos. Esto es equivalente a 13,032 fotogramas. Para la extracción de datos se utilizó Python. El proceso de extracción de datos se hizo con una librería llamada OpenCV. Esta librería permite el análisis de imágenes y la extracción de datos mediante el uso de aprendizaje automático (o Machine Learning en Inglés). Esta librería utiliza un archivo de detección facial pre-entrenado y solo lo va cargando cada vez que se desea analizar una imagen. Esta obtiene puntos del rostro tales como el contorno de la cara, las cejas, la nariz, la boca y los ojos.

7.5.5. Procesamiento de videos

La primera parte del preprocesamiento de los videos de las entrevistas fue anotar en un archivo de extensión csv, el segundo en los que el entrevistador termina la pregunta, el segundo en el que el entrevistado comienza a responder y el segundo en el que el entrevistado termina de responder. Esto se hizo con cada una de las preguntas, el total por entrevista era de 17 preguntas en la parte de verdad y otras 17 preguntas en la parte de mentira. Como segunda parte del preprocesamiento, se realizó la implementación de un programa en el lenguaje de programación Python que tomara de entrada un video de la entrevista, y en base a los tiempos anotados en el primer paso, se guardarán los fotogramas que estuvieran en los rangos anotados. Se hicieron dividieron en dos carpetas, antes de las respuestas y durante las respuestas, cada una de estas, tenía una subcarpeta con el nombre de la entrevista y el tipo de entrevista que había sido (teniendo una V o M como sufijo al código del entrevistado). Cada fotograma era guardado de la siguiente forma: El número de fotograma correspondiente, el número

de pregunta y el del segundo al cual correspondía dicho fotograma dentro de la entrevista. Como tercer paso se observaron los fotogramas de las entrevistas, y se fueron etiquetando manualmente los fotogramas en un 0 o en un 1, 0 si el rostro correspondía encajaba en la teoría del engaño y 1 si tenía una expresión genuina o si expresión neutral. Estos datos se fueron guardando en un archivo de extensión .csv, en donde se tenía el código del fotograma seguido de su la salida.

Debido a que se utilizarían algoritmos de aprendizaje supervisado, se necesitaba que todos los datos tuvieran una etiqueta que hiciera referencia a la clase la cual pertenecía. Las dos posibles clases serían verdad y engaño. Por lo tanto, se procedió a etiquetar manualmente las imágenes obtenidas en paso de pre-procesamiento. Se utilizó la teoría de engaño, utilizando el criterio de que engaño era cuando la persona intentará controlar el mensaje que estaba transmitiendo, y esto se podría interpretar en el rostro de la persona como una inconsistencia entre lo que se expresaba. Se lograron etiquetar 1043 fotogramas como engaño y se etiquetaron 1132 fotogramas como verdad.

7.6. Selección variables

En esta fase se procedió a elegir las variables con las cuales se iba a entrenar el modelo. Debido a que era un solo rostro el que aparecía en cada fotograma se investigó de qué forma se podría obtener información del rostro de una persona. Una de las opciones más viables que se encontró fue los puntos de referencia facial. Con la librería de Dlib, se encontró la implementación de un detector de caras control y predictor de 68 puntos de referencia facial.

7.6.1. Voz con redes neuronales probabilísticas

A partir de la base de datos generada se utilizó la plataforma KNIME para realizar el análisis exploratorio de los datos para determinar qué variables eran relevantes para su inclusión en los algoritmos de aprendizaje a aplicar más adelante.

7.6.2. Voz con k vecinos más cercanos

En esa etapa se hizo un análisis exploratorio con el objetivo de encontrar las variables más convenientes para el entrenamiento de algoritmos. Este se realizó con la ayuda de dos softwares dedicados a realizar estadísticas y gráficos. Estos son R Project y Knime, siendo el primero el más utilizado. Para esta etapa se realizaron múltiples análisis tales como matrices de correlación, gráficos de dispersión, árboles de decisión, regresiones logísticas y diagramas de caja.

7.6.3. Electroencefalografía

Un análisis previo mostró que trabajar con la media de los datos de los sensores era lo mejor para reducir la muestra a un solo punto en el tiempo, dado que la tasa de muestreo era de alrededor de 10 datos por segundo. Con los datos ordenados se creó un algoritmo para la creación de un solo archivo con estos con el cual se realizó el análisis exploratorio de los datos apoyados con el software de Knime, un software poderoso de código abierto para la creación de aplicaciones y servicios de análisis de datos. (Guide, s.f.) Se inició con un análisis de clustering de los datos para saber si existía alguna variable o relación que fuera decisiva o característica. Después de este análisis se realizó un árbol de decisión con el mismo software sobre los datos basándose en las variables de veracidad. Esto permitió ver qué variables si podrían ayudar para que un algoritmo tome la decisión correcta sobre los datos si el sujeto está mintiendo o no.

Con el conocimiento de las variables relevantes se limpiaron los datos de cualquier otra variable. Por tanto, se contruyó un programa para poder extraer toda la información en un archivo '.csv' para facilitar el entrenamiento de los modelos a construirse, manteniendo solamente la información relevante. Los datos de los sensores demostraron tener un compartimiento errático en ciertas ocasiones, su valor de medición era muy alto o muy bajo de manera exagerada. Debido a este comportamiento se normalizaron las mediciones de los sensores, de esta manera tampoco se vería afectado el comportamiento de la red neuronal, lo mismo se hizo con el algoritmo de KNN y SVM.

7.6.4. Puntos de referencia facial

En esta fase se procedió a elegir las variables con las cuales se iba a entrenar el modelo. Debido a que era un solo rostro el que aparecía en cada fotograma se investigó de qué forma se podría obtener información del rostro de una persona. Una de las opciones más viables que se encontró fue los puntos de referencia facial. Con la librería de Dlib, se encontró la implementación de un detector de caras control y predictor de 68 puntos de referencia facial. Tomando esto en cuenta y con la teoría de expresiones estudiada, se procedió a elegir obtener las siguientes variables del rostro: La distancia entre la ceja derecha con el ojo derecho, la distancia entre la ceja izquierda y el ojo izquierdo, la distancia entre las comisuras de los labios, la distancia entre los labios superiores e inferiores de la boca. Como segunda parte se implementó un programa que tomara de entrada un conjunto de códigos de entrevistados y a partir de estos buscar las imágenes previamente guardadas y sobre estas imágenes las cuales contenían el rostro de una persona realizando alguna expresión fácil, usar el predictor de rostros frontales y sobre este detector poder usar el predictor de los puntos faciales obteniendo las distancias mencionadas anteriormente. Se utilizó la distancia euclidiana del par de coordenadas, para calcular las distancias. Estas distancias fueron almacenadas en un archivo csv, junto que se había previamente etiquetado. Por lo tanto, se generó un archivo que tuviera las distancias calculadas junto con la salida. Estos serían los datos con los cuales se entrenaría el modelo.

7.7. N-gramas

Para obtener los n-gramas se analizaron los dos archivos que contenían el texto total de mentira y verdad. Se fue iterando sobre cada línea de texto que contenía el archivo, separando en elementos, es decir partiendo la estructura del corpus del texto en distintos elementos. Conforme analiza el texto va generando diccionarios que poseen las secuencias de tokens más comunes dentro del corpus y por cada una de estas secuencias que encuentra le va sumando uno al contador, de tal manera de que al final del algoritmo, nos devuelva los n-gramas que fueron más frecuentes dentro del texto a analizar.

7.8. Implementación de modelos

7.8.1. Voz con redes neuronales probabilísticas

Utilizando todas las variables escogidas en el análisis exploratorio de las variables extraídas se exploró la precisión de redes neuronales probabilísticas, variando θ minus y θ plus.

7.8.2. Voz con k vecinos más cercanos

Se eligieron tres algoritmos para desarrollar: k vecinos más cercanos (KNN), máquinas de vectores de soporte (SVM) y bosques aleatorios. El desarrollo de estos algoritmos tuvo dos fases, la primera fue la implementación de los algoritmos en R y la segunda utilizando el lenguaje Python, la cual fue la utilizada para la evaluación de porcentajes de precisión para encontrar el mejor algoritmo. Se contó con 879 tuplas de datos para el desarrollo de los algoritmos las cuales contenían las variables seleccionadas por parte del análisis exploratorio de variables.

Algoritmos en Python

En la implementación en Python se utilizaron dos librerías principales. La primera, scikit-learn, para los algoritmos de aprendizaje de máquina y la segunda, pandas, para la estructura de los datos a utilizar para los entrenamientos. El flujo del procedimiento fue similar para los tres algoritmos, por lo que se realizará una descripción general de los mismos y para las características individuales se darán detalles por algoritmo en la sección de resultados.

Por medio del módulo pandas se exportaron los datos para los algoritmos, de los cuales se asignaron las tuplas de datos a una variable, y a otra variable dependiente se le asignó el tipo al que pertenecía cada grupo de datos (verdad o mentira). Se dividieron los datos de entrada en un 70 % para entrenamiento y 30 % para pruebas, los cuales fueron utilizados para los entrenamientos de los algoritmos. En esta etapa se entrenó el modelo con los valores de entrenamiento obtenidos en el paso anteriormente descrito por medio de la función “fit” del modelo.

Se utilizó un “k folds” para realizar la validación cruzada de los algoritmos, con el cual por cada iteración se seleccionó un grupo aleatorio del conjunto de datos para determinar el grupo de entrenamiento y prueba. Por cada semilla se cambió el grupo de datos, y esta se aplicó para cada creación del modelo. Adicionalmente, se realizaron pruebas con diferentes parámetros específicos de los algoritmos. Cada vez que se repitió este procedimiento se almacenó el porcentaje de precisión para cada uno de los modelos.

Por último, se serializó el mejor modelo a por medio del módulo pickle con el cual se guardó un stream que contenía toda la información necesaria para reconstruir este objeto en otro script de Python. Esto se utilizó para la integración del modelo con la herramienta.

7.8.3. KNN con señales electroencefalográficas

Para este algoritmo se inició con una prueba por defecto provista por scikit-learn para la implementación del algoritmo de KNN. Esta prueba inicial consistió de una corrida con las siguientes variables: Hare, Sexo, Edad, Dsmt, Pebl, Cief, Cie, Ciep, Ciec, Ciem, Ciex, Cies, AF3, AF4, F3 y F4. Luego se buscó el valor óptimo de K (vecinos) para mejorar el modelo, que dice ser la raíz cuadrada de los datos (Pandey, 2017), se hizo una prueba de 10 corridas con $K = 15$, $K = 17$ y por último $K = 19$.

Luego se utilizó el K que presentaba la mejor precisión y se procedió a realizar una prueba con la variables de importancia: Hare, AF3, AF4, F3, F4, Pebl, Cief, Sexo y Edad; luego para corroborar aún más esta importancia, se hizo una prueba sin estas variables, es decir solo con las siguientes: Dsmt, Cie, Ciep, Ciec, Ciem, Ciex, Cies, AF3, AF4, F3 y F4. Por último, se procedió a normalizar la información y al obtener la mejor configuración para el entrenamiento del modelo, se entrenó con el 70 % de los datos y se probó con el 30 %. Es importante notar que con el porcentaje de entrenamiento se realizó validación cruzada para descartar la posibilidad de tener ‘overfitting’ en el modelo.

7.8.4. Redes neuronales con señales electroencefalográficas

Para la creación de la red neuronal se utilizaron las librerías de Tensorflow, específicamente las de “Deep Neural Network”. Tensorflow es una librería de código libre utilizado para facilitar las computaciones numéricas de alto rendimiento. Apoya grandemente los procesos de referentes a la inteligencia artificial permitiendo la creación y modelación de varios tipos de modelos, por ejemplo, redes neuronales. Este software permite crear una red neuronal a través del entrenamiento de ejemplos resueltos, mediciones de las que sabemos su valor de veracidad. Indicando solamente el número de capas y la cantidad de neuronas por cada una. (Tensorflow, 2018)

7.8.5. SVM con señales electroencefalográficas

Los modelos de aprendizaje de máquina se implementaron utilizando el lenguaje de programación *Python 3.6.0*. Se utilizaron las librerías *pandas*, *numpy*, *Scikit-Learn* y *TensorFlow* para realizar diversas implementaciones de los algoritmos de Máquinas de Vectores de Soporte. Estos algoritmos toman como entrada el conjunto de datos generado en la construcción del conjunto de datos de entrenamiento. La lectura de los archivos de entrenamiento se realizó por medio de la librería *pandas*. Las gráficas que permitieron realizar análisis de precisión y rendimiento se realizaron empleando la librería *matplotlib*. Se desarrolló el modelo empleando un ambiente virtual de Python, el cual se trabajó un sistema operativo *Xubuntu 18.04*, basado en *Debian*.

Se implementó la librería *TensorFlow* de *Google* para realizar los algoritmos de aprendizaje de máquina. Esta librería resuelve el problema de convergencia utilizando segmentos del conjunto de datos para realizar los cálculos matemáticos. La iteración de estos cálculos a partir de distintos segmentos llega a aproximar lo que sería el procesamiento del grupo completo del conjunto de datos.

La comparación de la precisión de predicción de los algoritmos de máquina empleados permite determinar el mejor algoritmo para esta tarea. La salida de los algoritmos desarrollados es entonces la precisión de la detección del engaño y la detección misma del engaño a partir de un conjunto de entrada. La salida de un conjunto de datos de una predicción en tiempo real estaría formada por un valor único, que representa si la persona mintió o no a lo largo de la prueba, y un valor de certeza. Este último estaría dado por la cantidad de valores repetidos de predicción por cada una de las observaciones del sujeto.

7.8.6. Redes neuronales convolucionales con imágenes de rostros

Para llevar a cabo el entrenamiento de datos se optaron por dos algoritmos de aprendizaje supervisado. El primero fue redes neuronales convolucionales y el segundo fue el de máquinas de soporte de vectores. Para el de redes neuronales convolucionales se hizo un redimensionamiento de la imagen a 48 x 48 píxeles con una escala de gris, por lo que se tenía un único valor entre 0 y 255, por cada uno de los píxeles. Se procedió a construir la red convolucional y para ello se utilizaron las capas de convolución, que permitía reconocer características dentro de la imagen, tales como curvas, líneas, bordes entre otras. Y la capa de agrupamiento para reducir la dimensión de la matriz de datos y poder extraer las características encontradas en las capas de convolución. Se intentó aumentar lo máximo posible la precisión de acierto, por lo que la arquitectura de la red que se utilizó fue la siguiente: Primero una capa de convolución, luego una capa de agrupamiento, seguido de dos capas convolucionales, después una de agrupamiento y finalmente una capa totalmente conectada, esta última servía para poder aprender de las características encontradas dentro de la imagen.

7.8.7. Máquinas de soporte de vectores con distancias de puntos de referencia facial

Para el segundo algoritmo de aprendizaje supervisado, se eligió las máquinas de soporte de vectores. Se utilizó la librería de scikit-learn de Python, y se hicieron pruebas con 2,175 datos como una homogeneidad del 50 % para cada conjunto de datos. Se probaron con diferentes funciones gamma y diferentes kernels para poder encontrar el mejor teniendo cuidado de que no se sobre ajustaran los datos al modelo. Se dividieron los datos en entre el 80 % para el conjunto de entrenamiento y el 20 % para el conjunto de prueba. Se utilizaron diferentes kernels, y se escogió el cual maximizaba la precisión de acierto.

7.9. Implementación de aplicación unificada

Basado el script de automatización para la predicción se implementó una interfaz amigable para el usuario que reduce el proceso de predicción a tres clicks, los cuales controlan el flujo de una entrevista. La interfaz fue implementada utilizando tecnologías web, usando VueJS como ambiente de trabajo para la parte visual, mientras que Flask fue utilizado para el control de la ejecución de los scripts de automatización.

El control de los scripts de predicción se implementó en un modelo multi-hilo, lo que permite la ejecución concurrente de todos los módulos del megaproyecto.

Cada módulo al finalizar su proceso envía sus resultados al servidor Flask, el cual los reenvía a la interfaz de VueJS por medio de SocketIO.

7.10. Pruebas finales

Se diseñó una entrevista la cual contaba con un grupo de preguntas básicas respecto a información del entrevistado y un grupo de preguntas relacionadas a un tema que se esperaba que las respuestas fueran engaño para evaluar los resultados de la herramienta.

8.1. Análisis exploratorio

La siguiente tabla refleja las características más representativas de los grupos generados por el clustering por k means, donde se obtuvo que el número óptimo de clusters para este problema era de 3 basado en el método del codo.




Figura 8.1: Método codo.

Variables	Grupo 1	Grupo 2	Grupo 3
Tiempo Respuesta	2.74s	3.04s	3.25s
Silencio	1.738s	1.738s	1.851s
Sexo Mujer	68 %	32 %	65 %
Sexo Hombre	32 %	68 %	35 %
Edad	20.61	20.61	20.63
Frecuencia	122.2 hz	54 hz	269.4 hz
Max Level	0.21	0.19	0.26
RMS Level	-33.34 db	-33.79 db	-31.74 db
Tipo Verdad	50.86 %	48.89 %	51.05 %
Tipo Mentira	49.24 %	51.11 %	49.94 %
Hare	11.42	12.37	10.79

Tabla 8.1: Análisis exploratorio.

8.2. Correlaciones con microexpresiones

El análisis exploratorio se realizó con una N de 18 participantes. Los datos representan las distancias entre algunas facciones faciales tomadas al momento de la pregunta y de la respuesta. Se promediaron los frames por segundo, por pregunta de las primeras 5 preguntas. Debido a que los datos se comportan de forma normal (Shapiro Wilk, $p > .05$), se utilizaron correlaciones de Pearson.

8.2.1. Con memoria de trabajo

No se encontraron correlaciones significativas (Correlación de Pearson $p < .05$) entre las 5 facciones de microexpresiones y el índice de memoria de trabajo en los momentos de verdad y de mentira.

8.2.2. Con velocidad de procesamiento

No se encontraron correlaciones significativas (Correlación de Pearson $p < .05$) entre las 5 facciones de microexpresiones y el índice de Velocidad de Procesamiento en los momentos de verdad y de mentira.

8.2.3. Con índice global de inteligencia emocional

En cuanto al Índice Global de Inteligencia Emocional, se encontraron correlaciones negativas significativas solamente para la microexpresión de Comisuras de la boca.

Veracidad	Pregunta	Momento	Correlación de Pearson	Singificancia
Verdad	Pregunta 3	Durante la pregunta	-.470	.049*
		Durante la respuesta	-.464	.50*
	Pregunta 2	Durante la pregunta	-.483	.042*
		Durante la respuesta	-.514	.029*
Mentira	Pregunta 3	Durante la pregunta	-.577	.012*
		Durante la respuesta	-.530	.024*
	Pregunta 4	Durante la pregunta	-.502	.034*
		Durante la respuesta	-.495	.037*
	Pregunta 5	Durante la pregunta	-.508	.031*
		Durante la respuesta	-.524	.026*

Tabla 8.2: Correlaciones entre Microexpresiones de Comisuras de la boca y CIE

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

Las correlaciones demuestran que a mayor el índice de inteligencia emocional, menor cantidad de movimientos en las comisuras de la boca. Este efecto fue más fuerte al momento de elaborar una mentira. Esto tiene sentido ya que según las observaciones de Paul Ekman, muchas personas utilizan la sonrisa para ocultar las emociones que les evoca la mentira (Ekman, 2014). Además, según el modelo de Salovey y Mayer las personas con un CIE mayor comprenden, perciben y manejan mejor sus emociones. Por lo tanto, pueden inhibir las emociones evocadas por el engaño, sin necesidad de sonreír para ocultarlas.

8.2.4. Con índices de habilidad de inteligencia emocional

No se encontraron correlaciones significativas (Correlación de Pearson $p < .05$) entre las 5 facciones de microexpresiones y los índices de percepción emocional ni el índice de facilitación emocional en las instancias de verdad y de mentira.

Con el índice de comprensión emocional, se destacan los siguientes resultados:

Veracidad	Pregunta	Momento	Facción	Correlación de Pearson	Significancia
Verdad	Pregunta 1	Durante pregunta	la Labios-Interior	.595	.009
		Durante respuesta	la Labios-Interior	.613	.007
	Pregunta 4	Durante pregunta	la Labios-Interior	.466	.051
	Pregunta 5	Durante pregunta	la Labios-Interior	.471	.048
		Durante respuesta	la Labios-Interior	.498	.035
Mentira	Pregunta 1	Durante pregunta	Labios-Exterior	.488	.040
			Labios-Interior	.700	.001
	Pregunta 3	Durante pregunta	Labios-Interior	.535	.022
			Labios-Exterior	.499	.035
	Pregunta 4	Durante pregunta	Labios-Interior	.481	.043
			Labios-Interior	.471	.048
		Durante respuesta	Labios-Interior	.498	.035
			Labios-Interior	.498	.035

Tabla 8.3: Correlaciones de Microexpresiones con Índice de Comprensión Emocional

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

Con el índice de manejo emocional, los resultados arrojan lo siguiente:

Veracidad	Pregunta	Momento	Facción	Correlación de Pearson	Significancia
Mentira	Pregunta 3	Durante pregunta	la Labios-Interior	-.469	.050
	Pregunta 5	Durante respuesta	la Labios-Interior	-.478	.045

Tabla 8.4: Correlaciones de Microexpresiones con Índice de Manejo Emocional

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

No se encuentra más relación entre las microexpresiones y los índices de percepción, facilitación y comprensión en comparación a manejo emocional, pero sí se encontró una relación diferente:

- Personas con mayores índices de comprensión emocional, muestran más microexpresiones en los labios interiores y exteriores. Esto se da tanto en el momento de verdad como en la mentira.
- Personas con mayor índice de manejo emocional muestran menos microexpresiones en los labios interiores cuando mienten.

8.2.5. Con psicopatía

No se encontraron correlaciones significativas (Correlación de Pearson $p < .05$) entre las cinco facciones de microexpresiones y la escala de psicopatía.

No se cumple con la hipótesis planteada de encontrar una relación entre las medidas de distancia de microexpresiones y el índice de psicopatía.

8.3. MANOVAS de medidas repetidas para tiempo de reacción y tiempo de demora

8.3.1. Con memoria de trabajo

No se encontraron efectos significativos (Lambda de Wilks, $p < .05$) del índice de memoria de trabajo en los momentos de verdad y de mentira sobre los tiempos de reacción y duración.

8.3.2. Con velocidad de procesamiento

En cuanto a la Velocidad de Procesamiento, medida por la prueba SDMT, se encontró un efecto en la interacción del momento de medida y el nivel de desempeño en la prueba, sobre el tiempo de duración de respuesta.

Origen	Suma Cuad	GL	Media Cuad	F	Sig	ETA	Potencia
Intersección	428.406	1	428.406	176.293	.000*	.859	1.000
SDMT	1.617	2	.808	.333	.720	.022	.098
Error	70.472	29	2.430				

Tabla 8.5: Comparaciones múltiples por veracidad y nivel de SDMT para tiempos de duración

Nota: Significancia $p < .05$; Suma Cuad=Suma Cuadrada, GL= Grados de Libertad, Media Cuad=Media Cuadrada, Sig=Significancia, ETA= Eta Cuadrado, Potencia= Potencia Observada; *Dato estadísticamente significativo

El efecto se puede observar (Figura 8.2) en el nivel promedio de los resultados de la prueba, al comparar el resultado en verdad y mentira. Esto significa que las personas que obtuvieron un resultado promedio en la prueba, elaboraron significativamente menos su respuesta al momento de decir una mentira, que al momento de decir la verdad.




Figura 8.2: Gráfica descriptiva de MANOVAS de Tiempo de Duración para SDMT

8.3.3. Con índice global de inteligencia emocional

En cuanto al CIE, se encontró también un efecto en la interacción del momento de medida y el nivel de desempeño en la prueba, sobre el tiempo de duración de respuesta.

Origen	Suma Cuad	GL	Media Cuad	F	Sig	ETA	Potencia
Intersección	377.228	1	377.228	168.099	.000*	.853	1.000
SDMT	7.011	2	3.505	1.562	.227	.097	.304
Error	65.078	29	2.244				

Tabla 8.6: Comparaciones múltiples por veracidad y nivel de CIE para tiempos de duración

Nota: Significancia $p < .05$; Suma Cuad=Suma Cuadrada, GL= Grados de Libertad, Media Cuad=Media Cuadrada, Sig=Significancia, ETA= Eta Cuadrado, Potencia= Potencia Observada; *Dato estadísticamente significativo

El efecto se puede observar (Figura 8.3) en el nivel promedio de los resultados de la prueba, al comparar el resultado en verdad y mentira. Esto significa que las personas que obtuvieron un

resultado promedio en la prueba, elaboraron significativamente menos su respuesta al momento de decir una mentira, que al momento de decir la verdad.

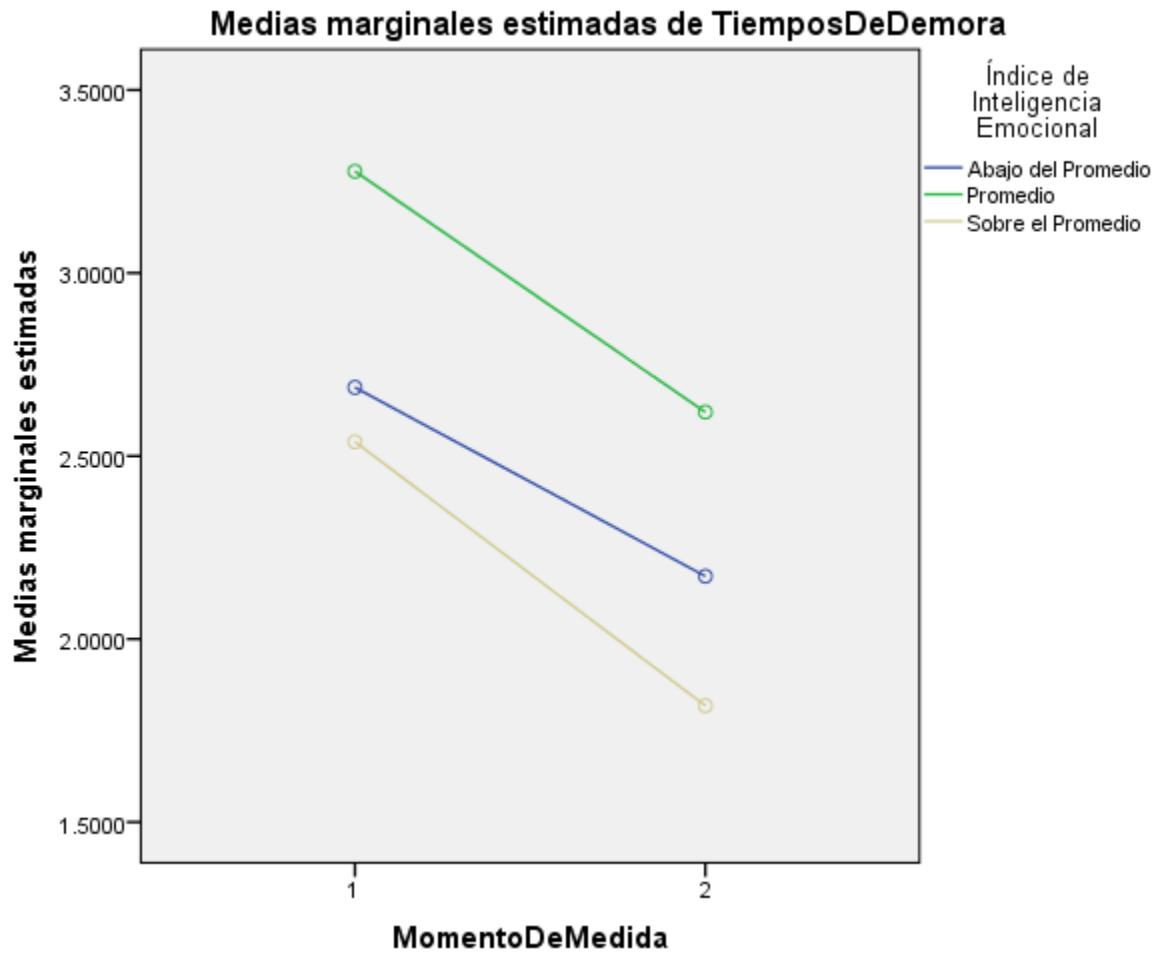


Figura 8.3: Gráfica descriptiva de MANOVAS de Tiempo de Duración para CIE

8.3.4. Con índices de habilidad de inteligencia emocional

Con el índice de percepción emocional se obtuvieron los siguientes resultados significativos:

Momento	Estadístico	Efecto	Valor	F	GL Hipótesis	GL Error	SIG	ETA
Tiempo de Demora	Lambda de Wilks	Momento de Medida	.495	29.584	1.000	29.000	.000*	.171

Nota: significancia $p < 0.5$, ETA CUAD = Eta Cuadrado, $n^2 > .05$ = es considerado un efecto fuerte, GL = Grados de Libertad

Tabla 8.7: Contrastes Multivariados de Índice de Percepción Emocional

Se observa un efecto (Figura 8.4) en la interacción entre el grupo dentro del promedio y el momento de medida (verdad y mentira) para el índice de percepción emocional en los tiempos

de demora. Se observa una diferencia significativa en sujetos con índice de percepción emocional promedio en base al momento de decir la verdad o decir una mentira. Sus tiempos de demora son menores en la mentira.




Figura 8.4: Gráfica descriptiva de MANOVAS de Tiempo de Duración para Índice de Percepción Emocional

Con el índice de facilitación emocional:

Momento	Estadístico	Efecto	Valor	F	GL Hipótesis	GL Error	SIG	ETA
Tiempo de Reacción	Lambda de Wilks	Momento de Medida	.876	4.11	1.000	29.000	.052*	.124
Tiempo de Demora	Lambda de Wilks	Momento de Medida	.874	4.18	1.000	29.00	.050*	.136

Nota: significancia $p < 0.5$, ETA CUAD = Eta Cuadrado, $\eta^2 > .05$ = es considerado un efecto fuerte, GL = Grados de Libertad

Tabla 8.8: Contrastes Multivariados de Índice de Facilitación Emocional

Hay una diferencia significativa en los sujetos con los índices de facilitación emocional más altos

al momento de decir la verdad o decir la mentira. Sus tiempos de reacción son mayores en la mentira y sus tiempos de demora son menores en la mentira. Este mismo efecto se ve en la interacción entre el grupo arriba del promedio y el momento de medida para el índice de facilitación emocional, tanto en tiempo de reacción como en tiempo de demora (Figura 8.5) y (Figura 8.6).




Figura 8.5: Gráfica descriptiva de MANOVAS de Tiempo de Reacción de Índice de Facilitación Emocional




Figura 8.6: Gráfica descriptiva de MANOVAS de Tiempo de Demora de Índice de Facilitación Emocional

Con el índice de comprensión emocional:

Momento	Estadístico	Efecto	Valor	F	GL Hipótesis	GL Error	SIG	ETA
Tiempo de Reacción	Lambda de Wilks	Momento de Medida	.802	7.16	1.000	29.000	.012*	.198

Nota: significancia $p < 0.5$, ETA CUAD = Eta Cuadrado, $n^2 > .05$ = es considerado un efecto fuerte, GL = Grados de Libertad

Tabla 8.9: Contrastes Multivariados de Índice de Comprensión Emocional

En sujetos con índice de comprensión emocional (Figura 8.7) debajo del promedio se observan tiempos de demora mucho menores al mentir y más elevados al decir la verdad.

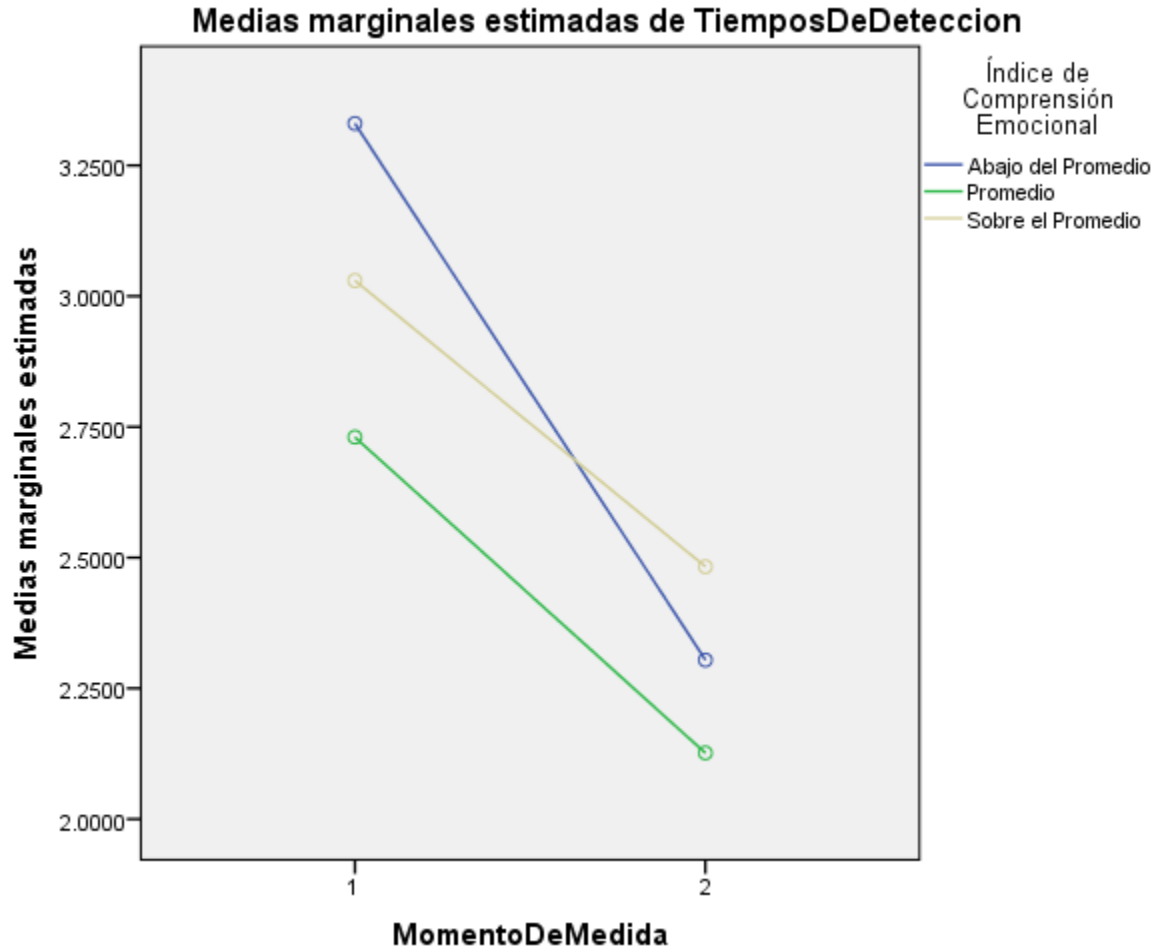


Figura 8.7: Gráfica descriptiva de MANOVAS de Tiempo de Demora de Índice de Comprensión Emocional

Finalmente, con el índice de manejo emocional:

Momento	Estadístico	Efecto	Valor	F	GL Hipótesis	GL Error	SIG	ETA
Tiempo de Reacción	Lambda de Wilks	Momento de Medida	.828	6.007	1.000	29.000	.021*	.172

Nota: significancia $p < 0.5$, ETA CUAD = Eta Cuadrado, $n^2 > .05$ = es considerado un efecto fuerte, GL = Grados de Libertad

Tabla 8.10: Contrastes Multivariados de Índice de Manejo Emocional

En el manejo emocional (Figura 8.8), los grupos se comportan de forma normal entre sí. Se observa diferencia entre el momento de verdad y el de mentira en cada grupo, siendo el grupo arriba del promedio el que cuenta con tiempos de demora menores tanto al decir la verdad como mentir. Se observa que cada grupo de manejo emocional demore menos en mentira que en verdad, en el grupo con un nivel sobre el promedio los tiempos de demora son más bajos y hay menos diferencia entre verdad y mentira.




Figura 8.8: Gráfica descriptiva de MANOVAS de Tiempo de Demora de Índice de Manejo Emocional

8.3.5. Con psicopatía

No se encontraron resultados significativos para el índice de psicopatía. Sin embargo, los resultados de los tiempos de demora (Figura 8.9) muestran demora mayor en el grupo sobre el promedio y una diferencia mínima entre las medias del momento de verdad con el momento de mentira.

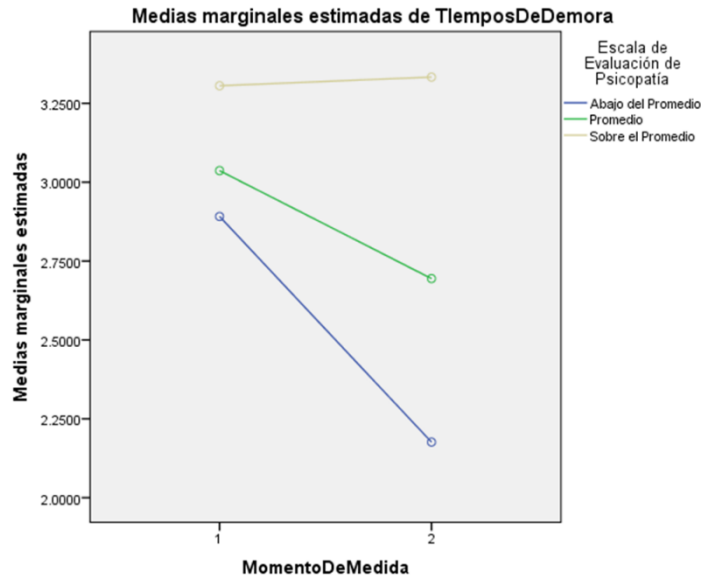


Figura 8.9: Gráfica descriptiva de MANOVAS de Tiempo de Demora de la Escala de Psicopatía

8.4. Correlaciones con datos de electrodos

El análisis exploratorio se realizó con una N de 15 participantes. Se presentan datos de electroencefalografía de actividad cerebral. Representan datos de voltaje en milivoltios. Las medidas de los electrodos utilizadas fueron: AF3, AF4, F3 y F3. Debido a que los datos no se comportan de forma normal (Shapiro Wilk, $p < .05$), se utilizaron correlaciones de Spearman.

8.4.1. Con memoria de trabajo

No se encontraron correlaciones significativas (Correlación de Spearman $p < .05$) entre los datos de señales electroencefalográficas y el índice de Memoria de trabajo en los momentos de verdad y de mentira.

8.4.2. Con velocidad de procesamiento

No se encontraron correlaciones significativas (Correlación de Spearman $p < .05$) entre los datos de señales electroencefalográficas y el índice de Velocidad de Procesamiento en los momentos de verdad y de mentira.

8.4.3. Con Índice Global de Inteligencia Emocional

Se encontraron correlaciones positivas significativas (Coeficiente de Spearman, $p > .05$) entre el Índice Global de Inteligencia Emocional y la activación electroencefalográfica del cerebro para el electrodo F4, tanto en verdad como en mentira.

Veracidad	Pregunta	Momento	Correlación de Pearson	Singificancia
Verdad	Pregunta 3	Durante la pregunta	-.470	.049*
		Durante la respuesta	-.464	.50*
	Pregunta 2	Durante la pregunta	-.483	.042*
		Durante la respuesta	-.514	.029*
Mentira	Pregunta 3	Durante la pregunta	-.577	.012*
		Durante la respuesta	-.530	.024*
	Pregunta 4	Durante la pregunta	-.502	.034*
		Durante la respuesta	-.495	.037*
	Pregunta 5	Durante la pregunta	-.508	.031*
		Durante la respuesta	-.524	.026*

Tabla 8.11: Correlaciones entre CIE y Actividad electroencefalográfica en F4

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

Los resultados muestran que a mayor el resultado del CIE, mayor activación registrada en el electrodo F4. Este electrodo mide la actividad en el área cerebral que cumple con la función de planeación estratégica de movimientos de expresión no verbal, la cual está asociada a factores como: la comunicación, la empatía y la intencionalidad (Camargo, s.f.) Estos factores están estrechamente relacionados con la inteligencia emocional.

8.4.4. Con Índices de Habilidad de Inteligencia Emocional

Se encontraron las siguientes relaciones significativas en el índice de percepción emocional:

Veracidad	Pregunta	Electrodo	Correlación de Spearman	de Significancia
Verdad	Pregunta 1	F4	-.690	.027
	Pregunta 2	F4	-.661	.038
	Pregunta 4	AF3	.716	.020
Mentira	Pregunta 1	F3	-.716	.020
	Pregunta 1	F4	-.826	.003

Tabla 8.12: Correlaciones entre Percepción Emocional y Actividad Electroencefalográfica

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

Con el índice de facilitación emocional:

Veracidad	Pregunta	Electrodo	Correlación de Spearman	de Significancia
Verdad	Pregunta 5	AF3	.688	.028*

Tabla 8.13: Correlaciones entre Facilitación Emocional y Actividad Electroencefalográfica

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

Con el índice de comprensión emocional:

Veracidad	Pregunta	Electrodo	Correlación de Spearman	de Significancia
Verdad	Pregunta 4	AF3	.724	.018*
	Pregunta 5	AF3	.724	.018*

Tabla 8.14: Correlaciones entre Comprensión Emocional y Actividad Electroencefalográfica

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

Finalmente, con el índice de manejo emocional:

Veracidad	Pregunta	Electrodo	Correlación de Spearman	de Significancia
Verdad	Pregunta 1	AF4	.649	.042*
	Pregunta 2	AF3	-.688	.028*
	Pregunta 5	F3	.703	.023*
		AF4	.675	.032*
Mentira	Pregunta 3	AF3	.701	.024*

Tabla 8.15: Correlaciones entre Manejo Emocional y Actividad Electroencefalográfica

Nota: Significancia $p < .05$, *datos que cumplen con un nivel estadísticamente significativo

El electrodo AF3 muestra mayor actividad cuando las personas dicen la verdad, únicamente difiere en el índice de Manejo Emocional, donde se activa menos cuando las personas dicen la verdad y se activa cuando las personas dicen mentiras. Un mayor índice de Manejo Emocional se relaciona con la activación de más áreas de la corteza prefrontal al decir la verdad.

8.4.5. Con psicopatía

No se encontraron correlaciones significativas (Correlación de Spearman, $p < .05$) entre los 4 electrodos y la escala de psicopatía para los momentos de verdad y mentira.

8.5. Voz con redes neuronales probabilísticas

Realizando el análisis exploratorio sobre todas las variables obtenidas, éstas fueron reducidas a:

- RMS lev dB
- RMS Tr dB
- Crest factor
- CIE
- PEBL
- DSMT
- HARE




Figura 8.10: Matriz de correlación para las variables extraídas

encontrando que éstas variables no están fuertemente correlacionadas entre sí (Figura 8.10).

Realizando las variaciones indicadas en los parámetros de una red neuronal probabilística se obtuvieron los resultados de la Figura 8.11

Certeza basada en variaciones de Theta Plus y Theta Minus	Theta Plus									Cohen's Kappa basado en variaciones de Theta Plus y Theta Minus	Theta Plus									
	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9		0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	
Theta Minus	0.1	66	72	74	74	74	74	72	72	0.1	0.271	0.37	0.391	0.391	0.358	0.391	0.358	0.337	0.37	
	0.2	-	70	72	74	74	74	72	72	0.2	-	0.348	0.37	0.425	0.391	0.391	0.391	0.37	0.37	
	0.3	-	-	70	72	70	68	72	68	0.3	-	-	0.348	0.37	0.348	0.294	0.37	0.37	0.326	
	0.4	-	-	-	70	66	68	68	66	68	0.4	-	-	-	0.348	0.271	0.326	0.294	0.271	0.294
	0.5	-	-	-	-	72	64	64	64	64	0.5	-	-	-	-	0.37	0.248	0.248	0.248	0.218
	0.6	-	-	-	-	-	68	60	60	64	0.6	-	-	-	-	-	0.294	0.142	0.142	0.218
	0.7	-	-	-	-	-	-	60	66	58	0.7	-	-	-	-	-	-	0.114	0.337	0.09
	0.8	-	-	-	-	-	-	-	64	66	0.8	-	-	-	-	-	-	-	0.181	0.184
	0.9	-	-	-	-	-	-	-	-	62	0.9	-	-	-	-	-	-	-	-	0.063

Figura 8.11: Resultados para redes neuronales probabilísticas

8.6. Voz con k vecinos más cercanos

Se tomaron en cuenta tres metodologías para la elección de las variables a utilizar: regresión logística, árboles de decisión y matrices de correlación. Se tomaron en cuenta los p-valores para decidir que variables eran más significativas para el modelo. De todo el conjunto de variables aplicando la regresión se seleccionaron siete variables que se encuentran en la Tabla 8.16

Variable	p-valor
Tiempo	0.062
rmsLevel	0.101
crest	0.119
rmsPk	0.208
PkLevel	0.217
rmsTr	0.277
maxLevel	0.304

Tabla 8.16: Variables elegidas de la regresión logística.

A partir del árbol de decisión realizado (Figura 8.12) se tomaron en cuenta las variables rmsPk, tiempo, minLevel y rmsLevel. Finalmente se realizó una matriz de correlación para encontrar la relación entre variables como se muestra en la Figura 8.13. En esta se puede observar que las variables no están fuertemente relacionadas. Significando el color azul una correlación positiva, el color rojo una correlación negativa y mientras más grande el círculo mayor la relación entre las variables que representan.

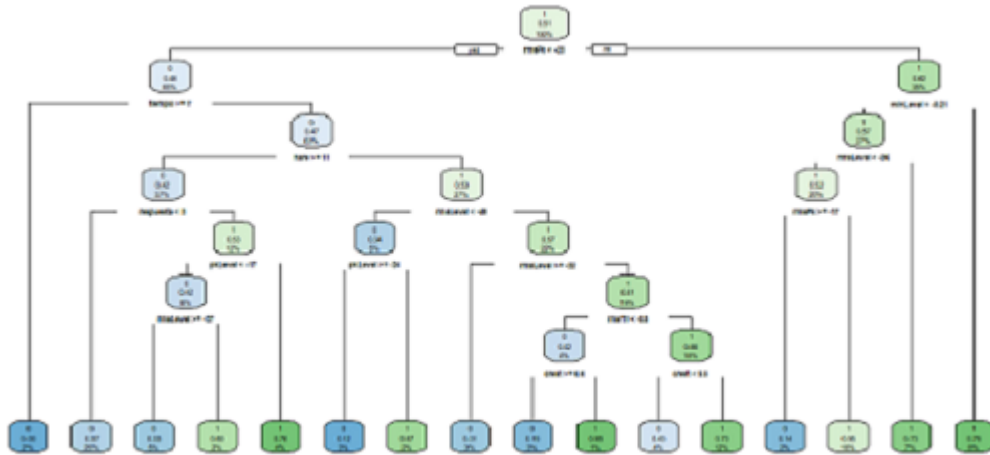


Figura 8.12: Árbol de decisión para la elección de variables.

Se analizó los resultados de las metodologías anteriormente mencionadas y en base a estos se seleccionaron las variables que se explican en la Tabla 8.17.

Se realizaron dos implementaciones en diferentes lenguajes de programación para los algoritmos k vecinos más cercanos, máquinas de vectores de soporte y bosques aleatorios. Se realizaron dos implementaciones en diferentes lenguajes de programación para los algoritmos k vecinos más cercanos, máquinas de vectores de soporte y bosques aleatorios. La primera implementación se realizó en lenguaje de programación R, de los cuales se obtuvo un porcentaje de precisión de 57.76%. Los algoritmos de máquinas de vectores de soporte y bosques aleatorios implementados en R fueron descartados por dificultades en el funcionamiento de la implementación, por lo cual no fueron utilizados

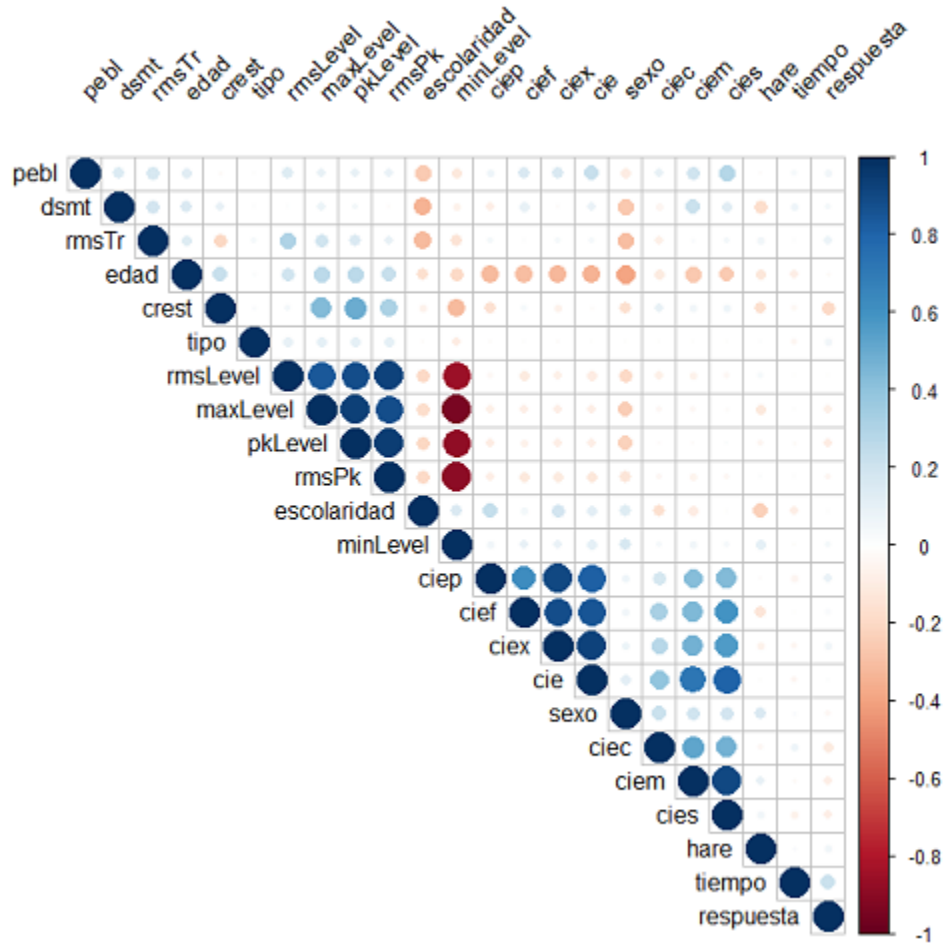


Figura 8.13: Matriz de correlación de los datos ingresados.

en el proyecto final.

Por motivos de facilitar y optimizar la integración de los algoritmos con la interfaz se realizaron los algoritmos de predicción en el lenguaje de programación Python utilizando la librería scikit-learn. Los resultados de las comparaciones entre diferentes parámetros para los algoritmos utilizados se encuentran en las siguientes tablas:

Después de múltiples pruebas se obtuvieron los mejores resultados para los diferentes algoritmos.

Variable	Significado
RMS level	Valor de RMS de un audio
RMS Tr	Valor máximo en una ventana de tiempo para RMS
RMS Pk	Valor mínimo en una ventana de tiempo para RMS
Min level	Valor mínimo de la frecuencia de un audio
Max level	Valor máximo de la frecuencia de un audio
Pk level	Peak de un audio
Cresta	Factor de cresta de un audio
Tiempo	Tiempo de respuesta

Tabla 8.17: Variables seleccionadas para el entrenamiento de algoritmos

Variables	k vecinos	algoritmo	leaf size	métrica	p distancia	peso	precisión
todas	3	auto	30	minkowski	manhattan	uniform	54.54 %
todas	5	auto	30	minkowski	manhattan	uniform	55.30 %
todas	7	auto	30	minkowski	manhattan	uniform	59.84 %
todas	11	auto	30	minkowski	manhattan	uniform	59.09 %
todas	19	auto	30	minkowski	manhattan	uniform	60.22 %
todas	23	auto	30	minkowski	manhattan	uniform	59.84 %
todas	27	auto	30	minkowski	manhattan	uniform	58.71 %
todas	3	auto	30	minkowski	euclidiana	uniform	56.43 %
todas	5	auto	30	minkowski	euclidiana	uniform	55.68 %
todas	7	auto	30	minkowski	euclidiana	uniform	57.19 %
todas	11	auto	30	minkowski	euclidiana	uniform	60.22 %
todas	19	auto	30	minkowski	euclidiana	uniform	59.09 %
todas	23	auto	30	minkowski	euclidiana	uniform	59.08 %
todas	27	auto	30	minkowski	euclidiana	uniform	59.94 %
todas	19	ball tree	30	minkowski	manhattan	uniform	60.22 %
todas	19	kd tree	30	minkowski	manhattan	uniform	60.22 %

Tabla 8.18: Resultados de diferentes parámetros para algoritmo k vecinos más cercanos.

Variables	kernel	gamma	Precisión
Todas	linear	auto	59.09 %
Todas	rbf	scale	55.68 %
Todas	sigmoid	scale	51.13 %
Todas	rbf	0.2	54.92 %
Todas	rbf	0.6	52.65 %

Tabla 8.19: Resultados de diferentes parámetros para el algoritmo máquinas de vectores de soporte.

Variables	n estimadores	Precisión
Todas	100	57.95 %
Todas	50	58.71 %
Todas	30	56.06 %
Todas	20	58.71 %
Todas	10	55.68 %

Tabla 8.20: Resultados de diferentes parámetros para el algoritmo bosques aleatorios.

Esto se muestra en la tabla 8.21, siendo k vecinos más cercanos, el modelo con mejor porcentaje de precisión.

Algoritmo	Mejor porcentaje de precisión
K vecinos más cercanos	60.22%
Máquinas de vectores de soporte	59.09%
Bosques aleatorios	58.71%

Tabla 8.21: Mejor porcentaje de precisión para los algoritmos evaluados.

	Mentira	Verdad		Mentira	Verdad		Mentira	Verdad
Mentira	70	66	Mentira	75	52	Mentira	77	62
Verdad	39	89	Verdad	56	81	Verdad	47	78

Figura 8.14: Matriz de confusión para k vecinos más cercanos. Figura 8.15: Matriz de confusión para máquinas de vectores de s. Figura 8.16: Matriz de confusión para bosques aleatorios.

8.7. N-gramas

Se generaron bigramas, trigramas y n-grama de 4 para las frecuencias de palabra en verdad y mentira, las cuales serán mostradas a continuación.

La siguiente tabla muestra las 15 palabras que fueron repetidas más veces dentro de los archivos de audio.

Número	Verdad	Frecuencia	Mentira	Frecuencia
1	Y	144	Me	103
2	Que	135	No	100
3	La	106	Y	97
4	Me	99	A	79
5	No	90	Que	71
6	De	72	La	63
7	Porque	71	Porque	61
8	Mi	71	Una	57
9	En	69	De	49
10	A	66	El	33
11	Una	59	Sí	32
12	Con	49	Un	31
13	Mis	41	En	30
14	Lo	41	Mi	27
15	El	40	Persona	24

Tabla 8.22: Frecuencia de palabras.

A continuación se detallan los distintos N-gramas generados.

Bigrama	Frecuencia
Me gusta	26
Porque me	21
Mis papás	17
Lo que	17
Que me	16
No sé	16
Con mi	16
Creo que	13
En la	13
Una persona	12

Tabla 8.23: Bigramas verdad.

Bigrama	Frecuencia
Me levanto	21
Una persona	20
A la	18
Y me	14
No me	11
Porque me	11
No tengo	11
Lo que	10
Que no	9
No sé	9

Tabla 8.24: Bigramas mentira.

Trigrama	Frecuencia
Me papás y	9
Con mis papás	8
Porque me gusta	8
Más o menos	7
Papás y mi	5
Y mi hermana	5
Que me gusta	5
Me parece interesenta	5
Porque creo que	5
Una persona que	5

Tabla 8.25: Trigramas verdad.

Trigrama	Frecuencia
Cómo una persona	6
No tenía nada	4
De la mañana	4
Planes a futuro	4
Vengo a la	4
A la U	4
A la universidad	4
Porque no tenía	3
Una persona triste	3
Una persona muy	3

Tabla 8.26: Trigramas mentira.

N-gramas	Frecuencia
Con mis papás y	6
Mis papás y mi	5
Porque me gusta mucho	4
Mis papás y mis	4
Papás y mis hermanos	4
Papás y mi hermana	3
Porque me parece interesante	3
Me parece interesante el	3
Me gusta mucho la	3
Trabajas en lo que	2

Tabla 8.27: N-gramas verdad.

N-grama	Frecuencia
Una persona muy enojada	3
Me iban a pagar	3
Me lavo los dientes	3
Porque no tenía nada	2
No tenía nada mejor	2
Tenía nada mejor que	2
Nada mejor que hacer	2
Una persona triste y	2
Persona triste y que	2
Para pasar el tiempo	2

Tabla 8.28: N-gramas mentira.

8.8. Señales electroencefalográficas con KNN

No. de Intento	Precisión
1	0.6911
2	0.6323
3	0.6176
4	0.6764
5	0.5735
6	0.5882
7	0.7205
8	0.7058
9	0.7352
10	0.6911

Tabla 8.29: Precisión del modelo con KNN, en 10 corridas con $K = 15$

No. de Intento	Precisión
1	0.6470
2	0.6911
3	0.7205
4	0.7058
5	0.6029
6	0.6323
7	0.7058
8	0.6176
9	0.6764
10	0.5441

Tabla 8.30: Precisión del modelo con KNN, en 10 corridas con $K = 17$

No. de Intento	Precisión
1	0.60
2	0.63
3	0.75
4	0.74
5	0.74
6	0.72
7	0.53
8	0.67
9	0.64
10	0.76

Tabla 8.31: Precisión del modelo con KNN, en 10 corridas con $K = 19$ sin normalizar los datos

No. de Intento	Precisión
1	0.3996
2	0.3878
3	0.4264
4	0.4411
5	0.4264
6	0.4884
7	0.5142
8	0.4742
9	0.4845
10	0.5287

Tabla 8.32: Precisión del modelo con KNN, en 10 corridas con $K = 19$ con datos normalizados

No. de Intento	Precisión
1	0.5588
2	0.5617
3	0.5470
4	0.5735
5	0.5294
6	0.5882
7	0.5029
8	0.5623
9	0.4176
10	0.5764

Tabla 8.33: Precisión del modelo con KNN, en 10 corridas con $K = 19$, para conjunto de variables relevantes

No. de Intento	Precisión
1	0.4705
2	0.6911
3	0.6470
4	0.4555
5	0.6917
6	0.5441
7	0.5882
8	0.5147
9	0.6764
10	0.5328

Tabla 8.34: Precisión del modelo con KNN, en 10 corridas con $K = 19$, excluyendo las variables relevantes

No. de Intento	Precisión
1	0.6470
2	0.7352
3	0.6764
4	0.7647
5	0.6470
6	0.5882
7	0.5882
8	0.6176
9	0.6562
10	0.6562

Tabla 8.35: Validación cruzada

	Precisión
Promedio de CV	65.57 %
Resultado de pruebas	64.25 %

Tabla 8.36: Resultados finales de pruebas con KNN

8.9. Señales electroencefalográficas con redes neuronales

Numero de Capas	Porcentaje de Confiabilidad
5	56.6
6	61.67
7	56.71
8	55.08
9	53.9
10	52.3
11	52.6
12	52.5

Tabla 8.37: Variación de porcentaje de confiabilidad con la cantidad de capas: número de neuronas fijo de 10 por capa

Número de Neuronas por Capa Escondida (6 capas en general)	Porcentaje de Confiabilidad
10	55.06
20	61.96
30	62.83
40	66.14
50	63.32
60	61.81
70	60.66
80	61.49
90	60.02
100	60.65

Tabla 8.38: Variación de porcentaje de confiabilidad con la cantidad de neuronas: número de capas fijo de 6

Función de Activación	Porcentaje de Confiabilidad
RELU	73.8
RELU6	52.5
CRELU	86.9
ELU	65.6
Softplus	63.9
Softsign	65.6
Sigmoid	52.5
Tanh	48.5

Tabla 8.39: Porcentajes de confiabilidad de la red neuronal con diferentes funciones de activación

8.10. Señales electroencefalográficas con SVM

Los resultados de la precisión de las distintas Máquinas de Vectores de Soporte, alimentadas por las variables seleccionadas, se presentan a continuación:

La siguiente figura muestra la precisión de la Máquina de Vectores de Soporte con distintos valores de C y γ . Los valores que brindaron la mejor precisión en la predicción del engaño fueron los que se emplearon como valores finales.

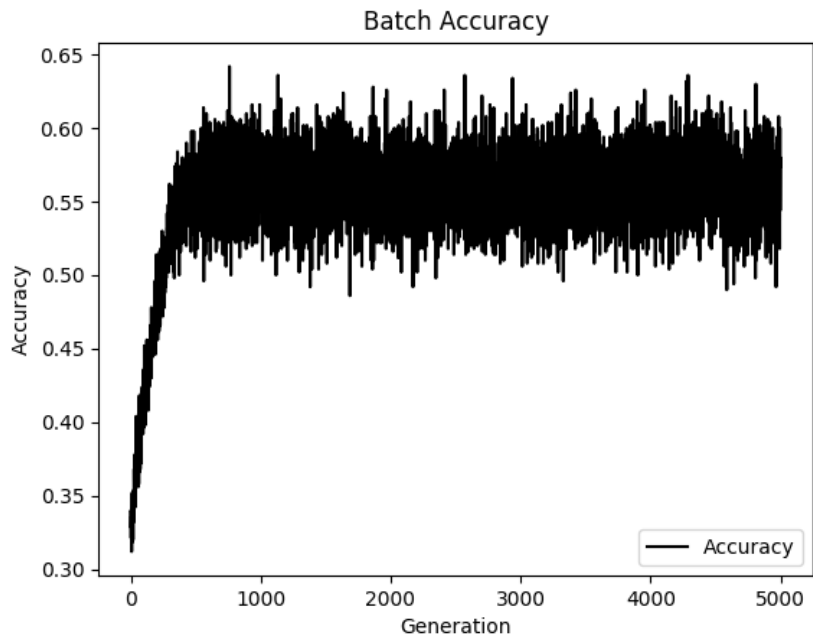


Figura 8.17: Precisión de la Máquina de Vectores de Soporte con kernel RBF.




Figura 8.18: Precisión de la Máquina de Vectores de Soporte con kernel Lineal.

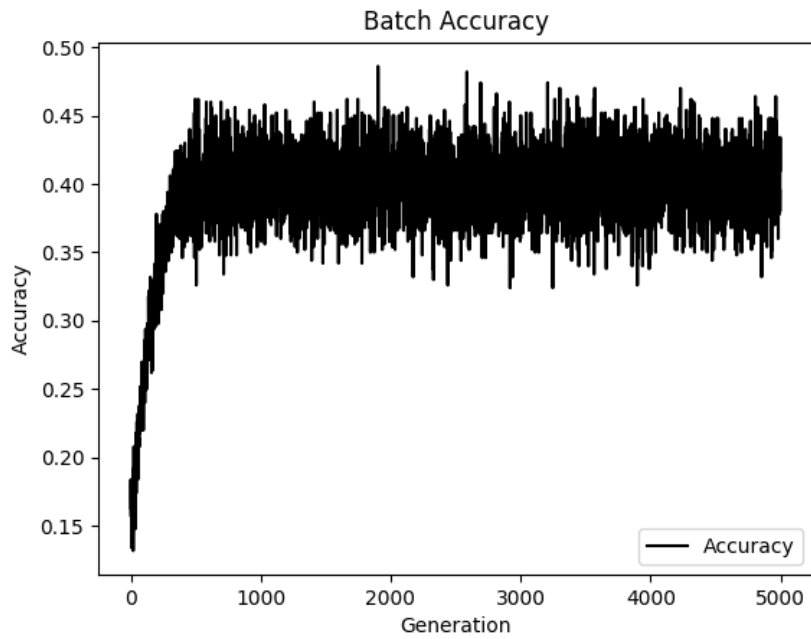


Figura 8.19: Precisión de la Máquina de Vectores de Soporte con kernel Polinomial.




Figura 8.20: Precisión de la Máquina de Vectores de Soporte con kernel RBF con distintos valores de C y γ .

8.11. Entrenamiento con máquinas de soporte de vectores con distancias

Para el aprendizaje supervisado se utilizaron la distancias del rostro, se fue variando empíricamente que distancias eran las más importantes por lo que se obtuvo que los mejores predictores fueron conseguidos con las siguientes características:

1. Distancia entre ojo derecho y ceja derecha
2. Distancia entre ojo izquierdo y ceja izquierda
3. Distancia entre comisura de labios
4. Distancia entre labios labio superior y labio inferior
5. Distancia entre labio superior interno y labio inferior interno

Con el kernel lineal se obtuvo una precisión de: 60.86 %

Con el kernel rbf se obtuvo una precisión de: 64.16 %

Con el kernel sigmoid se obtuvo una precisión de: 54.96 %

Se exploró más a detalle el kernel rbf, modificando los parámetros de γ y C , que producen un cambio en la creación de los límites que separan los datos, se obtuvo que para el kernel rbf y un γ de 0.01 se tenía una precisión de: 71.30 %

8.12. Entrenamiento con imágenes en red neuronal convolucional

Como arquitectura de la red se tenía tres capas compuestas por una convolucional seguida de un de agrupamiento (pooling) y un que conectaba a todas las demás capas.

Para el primer intento se entrenó a la red con imágenes de 48x48 píxeles a escala de grises, cada imagen tenía etiquetada un 1 si era una expresión neutral o si pertenecía a expresiones de la parte de verdad y 0 si tenía alguna expresión etiquetada como engaño.

Se obtuvo una precisión del 52.46 % con esta topología, y se decidió agregar más capas convolucionales y de agrupamiento, agregando una capa extra se obtuvo una precisión de 52.78 %. Agregando dos capas extra se obtuvo una precisión de 52.81 %



Figura 8.21: Rostro en escala de gris a una resolución de 48 por 48 píxeles

En el segundo intento se entrenó a la red con imágenes de 96x96 píxeles a escala de grises. Con la topología de 3 capas, se obtuvo una precisión de 52.87 %. Agregando dos capas extra se obtuvo una precisión de 52.89 %



Figura 8.22: Rostro en escala de gris a una resolución de 96 por 96 píxeles

8.13. Entrenamiento con características de los ojos en una red neuronal y máquinas de vectores de soporte

Para la red neuronal como arquitectura de la red se tenían 4 capas escondidas. La capa de entrada tenía un tamaño de 10 neuronas y la capa de salida tenía una sola neurona. Al concluir con el entrenamiento del modelo, se obtuvo un modelo que tenía una exactitud de 63.78 % para determinar si durante un vídeo de respuesta la persona miente o no. Se hicieron algunas pruebas después, para ver como se desenvolvía la red. Los resultados ante las pruebas es que acertó el 54 % de las veces. Una red con 54% de exactitud es una pésima red. Por lo que se decidió desarrollar otro tipo de red. Las máquinas de vectores de soporte era una buena opción ya que estas son buenas para obtener respuestas binarias. Los datos que se utilizaron para esta red fueron los mismos que se utilizaron para la primera red. De esta forma se obtuvo un 60 % de exactitud.

8.14. Patrones de comportamiento de los ojos

Se extrajeron todos los datos de lo que son las posiciones de los ojos en todo momento y adicional los parpadeos. En la gráfica de frecuencias de posiciones de los ojos se muestran las frecuencias de todos los movimientos de los ojos en las entrevistas.

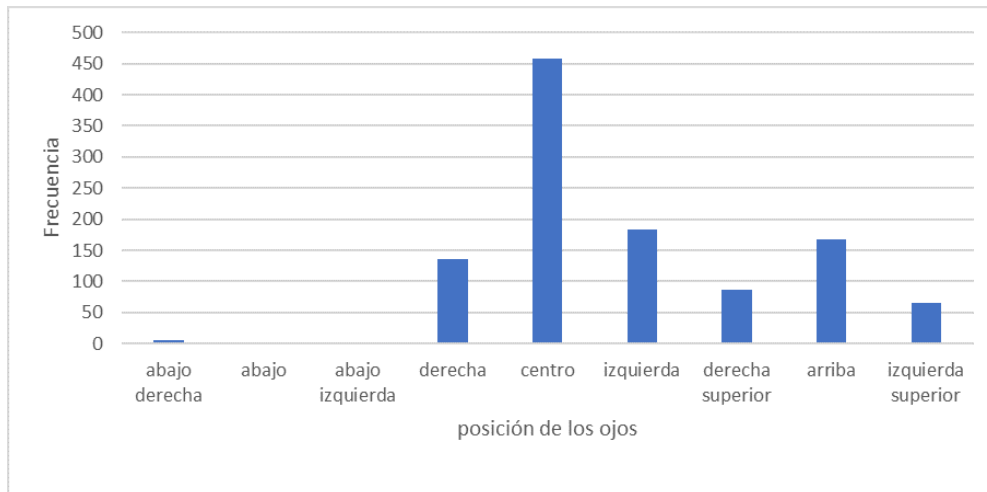


Figura 8.23: Frecuencias de posiciones de los ojos

En la gráfica de movimiento general de los ojos se puede apreciar que hubo más movimiento general en las entrevistas de solamente verdad que en las de mentira. Sin embargo, no es mucha la diferencia estando los movimientos en entrevistas de verdad en 52 %.

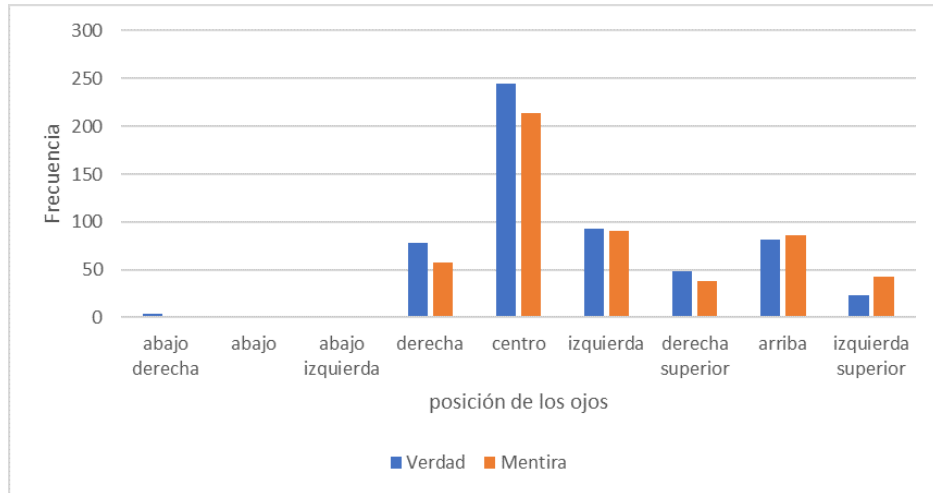


Figura 8.24: Frecuencias de posiciones de los ojos separados por verdad y mentira

En la gráfica de Frecuencias de posiciones de los ojos separados por verdad y mentira, podemos observar las distintas frecuencias del comportamiento de los ojos. A simple vista lo que mas resalta es la columna del centro. En esta podemos ver que hay mas popularidad cuando se ve hacia el centro y se esta diciendo la verdad. Lo cual queda con una de la creencias descritas en ".^A World of Lies", donde dicen que cuando se miente, existe menos contacto visual. También podemos apreciar que la posición más popular, después del centro, de la gráfica de arriba, la izquierda, la verdad y la mentira están casi empatados. Mientras que en resto de las posiciones no es el caso y se pueden notar una diferencia mayor. Donde se nota mayor diferencia es en la posición derecha, derecha superior e izquierda superior. En el caso de derecha el 57% de los datos fue en entrevistas de verdad. Para el caso de derecha superior el 56% fue en entrevistas de verdad. Por otro lado, el resultado de la posición de izquierda superior el mayor porcentaje fue en la de mentira con un 65%. Finalmente, en el gráfico de parpadeos durante las entrevistas se muestra un porcentaje sobre el parpadeo durante las entrevistas. Donde a simple vista podemos ver que hubo más parpadeos en las entrevistas de solo verdad que en las de solo mentiras.

8.15. Aplicación unificada

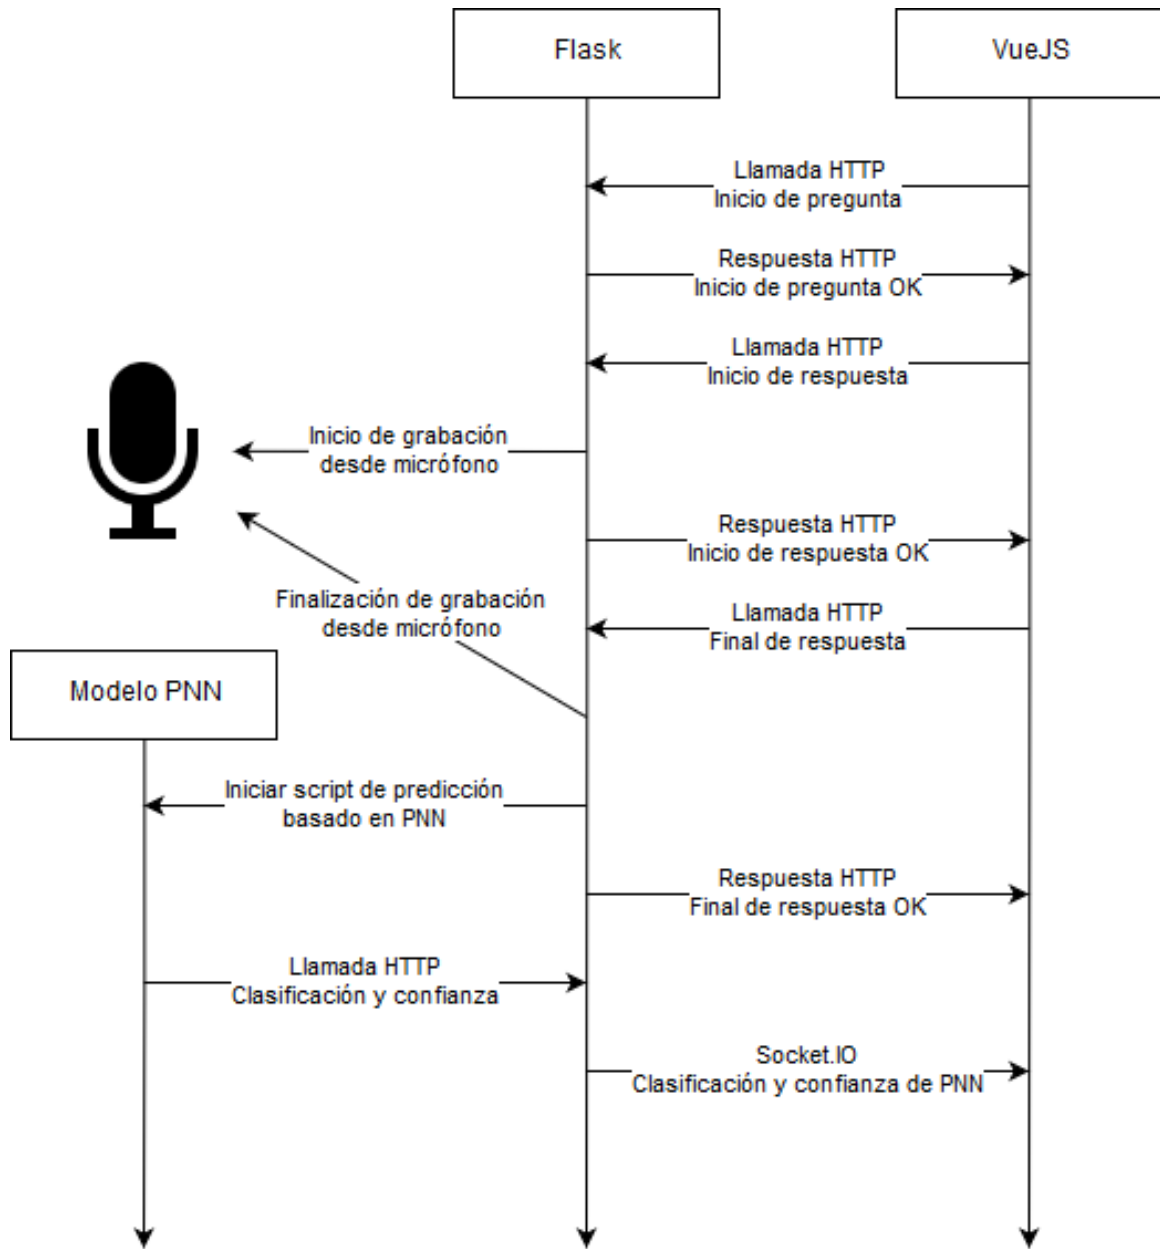


Figura 8.25: Diagrama de secuencia de la aplicación unificada utilizando los scripts de automatización para predicción

Discusión

Para la selección de variables a utilizar en el modelo de predicción por medio de voz utilizando redes neuronales probabilísticas se utilizó la matriz de correlación de todas las variables que se tenían a disposición se escogió un subconjunto que contuviera únicamente variables con un bajo coeficiente de correlación, reduciendo así la dimensionalidad de las muestras y el ruido que pudieran introducir variables no significativas o fuertemente correlacionadas entre sí. Observando la Figura 8.10 se pueden notar dos áreas de correlación, el área de las pruebas psicométricas y el área de las características extraídas de los segmentos de audio, sin embargo se nota también que no existe correlación significativa entre las pruebas psicométricas y las características extraídas de los segmentos de audio. Del grupo de las variables de las pruebas psicométricas fueron escogidas PEBL, DSMT, HARE y CIE, excluyendo el resto dada su correlación con la variable CIE. Del grupo de las características de los segmentos de audio se escogieron *crest*, *rmsTr* y *rmsLevel*, excluyendo el resto dada su correlación con la variable *rmsLevel*. Se escogió la variable *rmsLevel* ya que al no ser un valor extremo contiene información promedio del segmento de audio. Este modelo registró una certeza del 74%. En esta ocasión, al ser dos los parámetros variados en las configuraciones, las certezas y coeficientes de Cohen's Kappa se reportan en cuadros. Se utilizó una escala de rojo a verde para indicar los valores más bajos y más altos, respectivamente. Utilizando esta coloración resulta evidente que la certeza máxima coincide con el máximo coeficiente de Cohen's Kappa en la configuración $ThetaMinus = 0.2; ThetaPlus = 0.4$, la cual es conocida por ser la configuración estándar de las redes neuronales probabilísticas.

De los datos recolectados inicialmente se necesitaba obtener los datos de frecuencia ya que esta describe la tonalidad con la que un individuo se expresa y era una característica que se consideró importante, la cual sería explorada posteriormente. Para obtener las frecuencias se utilizó la transformada de Fourier a cada archivo de audio que se tenía disponible. Como se menciona en el marco teórico existen rangos dentro del espectro de la frecuencia en donde se puede diferenciar la frecuencia de la voz de un hombre y de una mujer. Al aplicar la transformada de Fourier en las grabaciones para obtener la frecuencia de las grabaciones se pudo comprobar que precisamente los hombres se encontraban alrededor de los 100 Hertz mientras que las frecuencias de las mujeres oscilaban alrededor de los 160 Hertz.

Para la selección de variables a utilizar para encontrar el mejor algoritmo entre *k* vecinos más cercanos, máquinas de vectores de soporte y bosques aleatorios se realizó un análisis exploratorio

basado en tres metodologías: regresión logística, árboles de decisión y matrices de correlación. Las variables elegidas basadas en resultados de la regresión logística se encuentran en la Tabla 8.16. Se evaluó los resultados para los p valores comparándolos con el valor ideal 0.05 o menor. Se observó que, en los resultados, únicamente la variable `respuesta` cumplía con la condición de que su p valor fuera menor a 0.05. Posteriormente se evaluaron cuales variables se acercaban más al valor esperado, y aunque solo el "tiempo" se encontraba relativamente cercano al valor, se tomaron en cuenta las variables `tiempo`, `rmsLevel`, `cresta`, `rmsPk`, `rmsTr`, `pkLevel`, y `maxLevel`. El análisis del árbol de decisión que se muestra en la Figura 8.12. Los nodos principales que se obtuvieron por medio de esta metodología son los siguientes: `rmsPk`, `minLevel`, `tiempo`, `rmsLevel`, `hare`, `pkLevel`, `rmsTr` y `cresta`. Finalmente se analizó el resultado obtenido de la aplicación de una matriz de correlación de variables, esta se puede visualizar en la Figura 8.13. Con esta matriz se representaron las correlaciones positivas en color azul y las negativas en rojo. La intensidad del color y el tamaño del círculo representaron a los coeficientes de correlación. De esta matriz se pudo encontrar correlación entre las variables `rmsLevel`, `maxLevel`, `pkLevel` y `rmsPk`. De los tres análisis anteriormente mencionados se eligieron las variables que se encuentran en la Tabla 8.17.

En la Tabla 8.18 se encuentran las iteraciones y los parámetros utilizados para evaluar la precisión del algoritmo k vecinos más cercanos en donde se utilizaron dos tipos de distancia: manhattan y euclidiana. Se modificó la cantidad k de vecinos en números impares y para cada uno de ellos se realizó una validación cruzada de tipo k folds, encontrando el mejor porcentaje de cada característica y evitando el sobreajuste de los datos. Como se observa en la tabla anteriormente mencionada, la mejor precisión fue de 60.22 % la cual se presenta en algoritmos con $k = 19$ y distancia manhattan, el cual fue seleccionado para esta metodología.

Para el algoritmo de máquinas de vectores de soporte se hicieron modificaciones en los parámetros de kernel y gamma para obtener porcentajes de precisión para la comparación de modelos. Las modificaciones se muestran en la Tabla 8.19. Para el modelo lineal se pudo utilizar el gamma automático obteniendo un 59.09 % de precisión en la predicción. Las demás modificaciones se realizaron con gamma en escala y kernel rbf y sigmoid. Por último, el algoritmo de bosques aleatorios se realizaron modificaciones a la cantidad de estimadores del modelo. La configuración por defecto que utilizó Python fue la de menor porcentaje de precisión respecto a las demás iteraciones. El valor óptimo se encontró con 50 estimadores siendo este un 58.71 % si valor más alto. Los detalles se pueden observar en la Tabla 8.20

Tomando en cuenta los resultados con la mejor precisión para predecir la verdad o la mentira, se realizó un cuadro comparativo con los tres porcentajes de precisión más altos (Figura 8.21), y para cada uno de estos modelos se realizó una matriz de confusión. Con esto se buscó evaluar los resultados de la clasificación de los datos de prueba para los algoritmos. Estas matrices se pueden observar en las figuras 8.14, 8.15 y 8.16.

La elección del mejor modelo de clasificación de los tres algoritmos planteados se realizó basada en dos criterios. Los resultados del análisis de las matrices de confusión y los porcentajes de precisión para cada uno. Se tomó en cuenta que el objetivo del megaproyecto era la detección del engaño por lo que en las matrices de confusión fue importante analizar las respuestas de mentira que eran clasificadas como verdad. Por lo anteriormente mencionado, se eligió a k vecinos más cercanos con $k = 19$, como mejor modelo tomando en cuenta que su porcentaje de precisión fue el más alto y que los resultados de la matriz de confusión representan el error más bajo en la mala clasificación de la mentira con un total de 39 de 264. Este modelo fue serializado y utilizado para la predicción del engaño en la aplicación final.

Cuando se analizó los datos recabados por el emotiv se notó que el sensor AF3 era el que reportaba más variación en la frecuencia a comparación de los otros sensores, la frecuencia de este sensor variaba entre 500 mV y 1200 mV, mientras que el resto se quedaba en un rango entre 500mV y 900 mV. Sin embargo, se pudo hacer una diferenciación clara entre todos los sensores, con los cuales se procedió a un análisis exploratorio para ser más exhaustivos al igual que el resto de módulos.

Cuando se hizo un análisis por medio de clustering hecho con Knime se obtuvo en el primer cluster que todos los participantes mentían y que todas eran mujeres. En el segundo cluster remarcaba que la mayoría eran hombres y que la mayoría decían la verdad. En el tercer cluster, siendo el de mayor cantidad, no se notó ninguna característica del grupo que nos indicara algún tipo de clasificación. Debido a que en el análisis de clustering solo se notó el sexo como una variable determinante con la veracidad nos indicó que efectivamente era variable importante para el modelo, pero también que era necesario otro análisis para eliminar más variables. El árbol de decisión fue de gran ayuda con esto dando más variables y filtrando otras, además que remarco que el sexo era una variable importante.

Al momento de entrenar los algoritmos con señales electroencefalográficas se tuvo que hallar distintas formas de optimizar los modelos de manera que la precisión fuera alta y correct. En el caso del algoritmo de KNN, se tenía una regla para hallar la cantidad de vecinos óptimo que consiste en calcular la raíz cuadrada de los datos en este caso de 337, el resultado era de 18.5, sin embargo, el número debía ser impar para evitar empates al momento de clasificar (Hassanat, Abbadi, y Alhasanat, 2014). Se trabajaron distintos k, alrededor de este valor, es por eso que se hicieron pruebas con los valores de 15, 17 y 19. El que obtuvo el mejor resultado fue con un $k = 19$ con una precisión de 76% para predecir.

Al tener el k que maximizaba esta precisión es entonces que se decidió utilizar las variables mencionadas anteriormente para el entrenamiento. Sin embargo, los resultados mostraron que la precisión era baja utilizando este conjunto de variables por lo que se procedió a utilizar el resto de las variables que se tenían disponibles, esto se pudo observar en las corridas hechas para generar las tablas 8.33 y 8.34. Por tanto, las variables reportadas como más influyentes en efecto aumentaban la precisión, pero no por si solas, este modelo si necesitaba del resto de variables, solamente se excluían las variables de escolaridad y lateralidad.

Entre las observaciones también está la normalización de los datos, que KNN funciona mejor al normalizar los datos. En este experimento ese no fue el caso, como se puede observar en las tablas 8.31 y 8.32. Normalizar facilita el proceso de cálculo de distancias, lo cual es mejor para este algoritmo, pero el rango de las dimensiones tiene que ser el mismo. Es decir, que, si todos los datos se normalizaban, todos los datos tenían que estar en el mismo rango, pero ese no fue el caso. Por lo que, al calcular las distancias entre dimensiones, el modelo disminuyó su precisión. El tipo de normalización influye en los modelos, aunque para KNN, la normalización Z, es la que da mejores resultados (Pandey, 2017) .

Para este conjunto de datos, ese no fue el caso, la normalización empeoraba la precisión, de igual manera la validación cruzada hecha con el conjunto de datos, presento una reducción en la precisión del modelo. En cuanto al porqué en la reducción de precisión del modelo con normalización se debe a las escala que presentaban las distintas dimensiones(variables) de entrenamiento que a pesar de que una escala quedara entre $[-1, 1]$ otros quedaban en $[-2, 2]$, es por eso que la normalización en este conjunto de datos produjo un resultado negativo. Luego, en cuanto a la validación cruzada y la precisión real del modelo se trato de hallar un porcentaje de precisión donde tanto la validación cruzada y el conjunto de pruebas presentaran un resultado similar. Se dejó el programa ejecutándose hasta obtener un resultado similar y se obtuvieron los resultados descritos en la Tabla 8.36.

Para la selección de capas no existe un número ideal o una fórmula que permitiera saber exactamente cuántas se deben usar por lo que se tanteo números bajos primero y se observó el resultado. Para variar solamente el número de capas primero se realizaron pruebas con el número arbitrario de 10 neuronas por capa. Los resultados de estos se observan en la Tabla 8.37 Como se observa el número de capas con mayor porcentaje es de 6. Al tener el número fijo de capas necesarias se empezó a variar el número de neuronas por campo. Estas variaciones se pueden observar en la Tabla 8.38 Con estas pruebas solamente se llegó a un porcentaje de 62.14 con 40 neuronas por capa, haciendo variaciones de menor magnitud en las neuronas se llegó con un porcentaje máximo de confiabilidad de 73.8 con 6 capas y 48 neuronas por cada capa. Todas estas pruebas se realizaron con la función de activación ReLu debido a que es la más utilizada en el campo y se acoplaba al comportamiento

de los datos. Se decidió probar con varias funciones de activación por capa para verificar si existía una que proveyera un mejor porcentaje de confiabilidad. La función CReLU, una variación de la función ReLU, demostró tener un mejor porcentaje de confiabilidad que cualquier otra función de activación. Los resultados se observan en la Tabla 8.39. Al llegar a tal alto porcentaje con la función CReLU se sospechó de overfitting. Por lo tanto, se realizaron pruebas de desempeño con los datos de entrenamiento al modelo ya entrenado. Estas pruebas se realizaron con muestras variadas de tamaño. En promedio se obtuvo que estas pruebas tenían un porcentaje de confiabilidad de 84.3.

En la red neuronal finalmente se llegó a un máximo de porcentaje de confiabilidad de 86.9 con la función CReLU en 6 capas con 48 neuronas cada una. Aunque este porcentaje de confiabilidad no es tan alto como el porcentaje que se ha estimado del polígrafo aun se considera un porcentaje aceptable. Sobre todo, si se toma en cuenta que la muestra para entrenar y poner a prueba la red neuronal no fue tan grande y la incertidumbre que pudo ser causada durante la obtención de los datos, por la posición de los sensores o los factores externos en la entrevista, si es considerable. Demuestra ser difícil la definición correcta de una red neuronal por la falta de existencia de una fórmula exacta o aproximada que nos de una idea o rango sobre la cantidad de neuronas o capas. De la misma manera afecta que sea de la misma naturaleza las funciones de activación, solo permiten el probar recurrentemente y llegar al valor más alto posible con la combinación elegida. Esto demostraría ser una gran limitación en redes muy grandes, con muchos datos o muchas variables. En la experimentación para identificar la mejor cantidad de capas no se vio mucha diferencia con los porcentajes de confiabilidad, solo en los números extremos de capas. Esto probablemente se dio porque se trabajó todas las pruebas con el mismo número de neuronas y que este era inadecuadamente bajo. Siendo aún más obvio cuando se experimentó con el número de neuronas, obteniendo 10 neuronas el peor porcentaje. Pero era necesario colocar un número arbitrario de neuronas para tener un punto de partida para la experimentación. Aun de esta manera fue posible notar un cambio en los porcentajes que nos llevó al número correcto de capas. Durante la experimentación para encontrar el número de neuronas que optimizaba el porcentaje de confiabilidad fue más notable la diferencia entre cada decena de neuronas con las que se probó. Fue más claro que al llegar a cierto número crecía más hasta llegar a un máximo. Aun cuando los números alrededor fluctuaban, en los extremos si se veía un decremento considerable sobre todo con los valores bajos. Por la misma fluctuación con las decenas vecinas fue que se empezó a probar número por número la cantidad de neuronas hasta que se llegó al porcentaje más alto que se obtuvo en esta fase. No se considero que la red tuviera overfitting pues el porcentaje de confiabilidad obtenido en las pruebas no fue alto. Además era muy cercano al porcentaje de confiabilidad previamente obtenido con la red neuronal. Con esto se considera que efectivamente este porcentaje es el verdadero y no era necesario aplicar dropout o alguna otra técnica para reducir el overfitting.

Los resultados de la precisión de los algoritmos de máquina de vectores de soporte indican una clara mayor precisión por parte del algoritmo con kernel gaussiano RBF. Debido a la naturaleza de los datos, se esperaba que el kernel lineal tuviese baja precisión. El kernel polinomial no arrojó una precisión suficientemente elevada como para considerarse "bueno". Esto puede deberse a la naturaleza de los distintos tipos de datos utilizados. A pesar de poder haber sido modelado, la complejidad de estos al utilizarse en conjunto pudo haber causado un *overfitting* del modelo con estos datos, reduciendo la precisión de predicción al momento de utilizar datos nuevos.

La precisión del kernel gaussiano RBF se vio mejorada con valores de γ cercanos a 2^{-9} y de C cercanos a 2^3 . Sin embargo, esta precisión no se vio ampliamente mejorada con respecto a otros valores empleados. Dejando cincuenta y ocho (58) por ciento de precisión como mejor valor predictivo de los datos. A pesar de ser un valor alto para este tipo de pruebas, se vio un mucho mejor rendimiento con el algoritmo *K Vecinos Cercanos* empleando en otro módulo de análisis electroencefalográfico del proyecto. Por lo cual, a pesar de que Máquina de Vectores de Soporte logra un valor de predicción aceptable, se recomienda emplear *K Vecinos Cercanos* para el análisis electroencefalográfico en la detección del engaño.

Los resultados obtenidos en la clasificación de las imágenes jugó un papel importante, puesto que

esta fue la entrada de los algoritmos de aprendizaje supervisado utilizado. En este etiquetado de datos se tomó en consideración la teoría del manejo facial, que esta incluye el campo microexpresiones. En primera instancia la calificación del rostro, muchas de los entrevistados en la parte de engaño hacían una calificación su expresión facial de sorpresa con una sonrisa. Es decir que, para manejar la sorpresa o miedo, sonreían. Esto fue muy recurrente en los entrevistados, sin embargo, se decidió no tomar a sonrisa como engaño puesto que estaba en partes de las entrevistas, lo que iba a generar falsos negativos. En cuanto a la modulación se observó que cuando los entrevistados, no lograban pensar de forma rápida en una respuesta de mentira, modulaban su expresión facial para hacerla más notoria. Por ejemplo, muchas veces en la pregunta ¿Qué lo motiva a trabajar/estudiar todos los días?, en la parte de mentira, las personas no sabían que decir, entonces al responder exageraban una expresión de sorpresa. Esta fue catalogada como expresión de engaño. En cuanto a la simulación de las expresiones faciales hubo entrevistados que, al mentir en alguna pregunta, fruncían la señal mostrando una expresión de enojo. A este si se catalogaron como engaño, puesto que en la parte de la entrevista de verdad no se vieron reflejos de esta expresión. En algunos casos también se vio la expresión de asco justo antes de mentir, esto también podría entrar en la categoría de simulación.

Los puntos de referencia facial fueron de bastante ayuda para calcular la distancia de las partes de la cara. Estas daban una buena aproximación de cómo estaba la estructura de rostro. Algo importante que se tomó en cuenta fue normalizar de alguna forma las distancias, esto se logró a través de todas las distancias calculadas, multiplicarlas por un factor de distancia pupilar calculada previamente. Parece ser que al concentrarse en las partes del rostro tales como cejas, ojos y labios, puede llegar a ser más efectivo al tener datos más precisos de la estructura del rostro. En los resultados se encontró que, mediante máquinas de soporte de vectores, el mejor kernel es. Esto puede deberse a que encuentra una solución suavizada que intenta separar todos los puntos y considerando la naturaleza de los datos se espera que pequeñas diferencias en los datos puedan determinar si una expresión o no se encuentra como engaño. Los parámetros de C y γ propuestos aumentan considerablemente la efectividad. Primero el parámetro γ define que tan lejos los puntos al margen separador de los datos. Con un valor alto de γ , solo los puntos cercanos al margen son considerados y al tener un valor bajo de γ los puntos más lejanos serán lo que se tomarán en cuenta. La γ utilizada fue de 0.01, es decir una γ bajo. Los puntos algo alejados de la margen serán los que influyen a él margen, cabe destacar que entre menor se hacia el γ empezaba a bajar la efectividad.

En cuanto al entrenamiento con la red neuronal convoluciones se pueden encontrar que la eficiencia es muy inferior a la máquina de soporte de vectores, esto puede deberse a varios factores. Primero a que la entrada de imágenes se tenía pocos datos y poca variedad en cuanto a rostros. A pesar de aumentar el número de capas no se veía un aumento significativo. A parte de que el costo de procesamiento es muchísimo más alto que de las máquinas de soporte de vectores. Se puede ver el costo de procesamiento y la eficiencia del este tipo de algoritmo no se ve bien recompensado. Incluso al dar de entrada imágenes mucho mayores, no se observa una mejora significativa. Es probable que una mayor cantidad de imágenes, se puedan encontrar patrones.

Para la implementación de la interfaz de usuario se escogió el ambiente web, tomando ventaja de su agnosticismo de plataforma, es decir, que puede ser utilizado sin importar la combinación de Hardware y Software de la computadora, siempre y cuando se tenga un navegador web. La implementación del Frontend en VueJS permitió que la interfaz de usuario fuera rápida de programar a la vez que le da retroalimentación al usuario de qué está pasando en cualquier momento de la ejecución. (Ver anexo E)

Gran parte de la complejidad del sistema integrador se encuentra en el Backend por su implementación multi-hilo, necesaria ya que se buscó que las ejecuciones de cada módulo no perjudicaran la ejecución de un módulo ajeno, asegurando así estabilidad del sistema y capacidad de recuperación a un estado conocido. La comunicación del Frontend con el Backend se basó en llamadas HTTP y eventos de Socket.IO, permitiendo así que todas las llamadas HTTP fueran contestadas inmediatamente mientras que los resultados que los módulos de predicción eventualmente procesan son enviados por medio de eventos de Socket.IO. En la Figura 8.25 puede observarse un diagrama de

secuencia ejemplificando el detalle de las interacciones del Frontend, Backend y el script que ejecuta el modelo de predicción basado en voz utilizando redes neuronales probabilísticas.

Se hizo un primer acercamiento hacia la creación de una herramienta integral que combinara medidas de engaño de tres tipos: microexpresiones, señales de voz y actividad eléctrica del cerebro. Este es un paso importante para ayudar a los profesionales a detectar el engaño de forma más completa y efectiva.

La investigación evidencia la presencia de componentes cognitivos en la elaboración del engaño en personas de la comunidad UVG. Esto hace evidente la necesidad de seguir estudiando este fenómeno en esta y otras poblaciones

Los análisis de correlación utilizados en las microexpresiones encontraron relación cercana con la habilidad de comprensión emocional. Esta relación estuvo presente en los momentos de verdad y mentira, tanto durante la pregunta como durante la respuesta y se manifestó principalmente en el área de labios interiores del rostro. También se encontró correlación entre el índice global de inteligencia emocional con las microexpresiones en las comisuras de la boca, principalmente al momento de engaño. Esto puede ser evidencia de que la gente suele sonreír al mentir para ocultar sus emociones. Se encontró además una relación entre las microexpresiones con la habilidad de manejo emocional, pero únicamente en la mentira. Estos se manifestaron exclusivamente en los labios internos del rostro.

A partir de los análisis estadísticos MANOVAs se encontraron efectos en cada una de las habilidades de inteligencia emocional en los tiempos de demora de respuesta. Únicamente se vio este efecto en los tiempos de reacción en la facilitación emocional. Estos efectos se dieron únicamente en el momento de medida y no se comprobó la relación directa de cada índice sobre el momento de medida. También se encontraron efectos de interacción para las variables velocidad de procesamiento y el índice de inteligencia emocional en los tiempos de duración, o elaboración de respuesta, al momento de elaboración del engaño, en el que los tiempos eran mayores.

En cuanto a la activación electroencefalográfica, con los análisis de correlación se encontraron relaciones entre los índices de inteligencia emocional y diversos electrodos. Se destaca la presencia del electrodo AF3 en cada uno de los índices. Para mentira, únicamente la percepción y el manejo se relacionaron con los electrodos F3, F4 y AF3. Además, se mostraron efectos de interacción entre el índice de inteligencia emocional y la actividad electroencefalográfica medida por el electrodo F4 (implicado en la de planeación estratégica de movimientos de expresión no verbal), tanto al decir la verdad como al momento de elaborar una mentira.

Una matriz de correlación es una manera eficaz para determinar un subconjunto de variables a utilizar en un algoritmo de aprendizaje de máquina, evidenciando qué variables pueden ser omitidas debido a que tienen una información muy similar a otra variable.

La herramienta KNIME permite un rápido prototipado y prueba de flujos de trabajo utilizando algoritmos de aprendizaje de máquina, proveyendo una interfaz de arrastrar y soltar nodos de ejecución.

Al entrenar algoritmos de aprendizaje de máquina para una clasificación binaria se debe buscar que la certeza se aleje lo más posible de una certeza del 50 %, ya que una certeza del 50 % es la que se esperaría de un clasificador aleatorio. En caso de obtener una certeza menor al 50 % y ser una clasificación binaria simplemente pueden invertirse las etiquetas resultantes y obtener la certeza complementaria.

Además de la certeza de un algoritmo, es importante tomar en cuenta la distribución de falsos positivos y falsos negativos, ya que puede que no importe que la certeza no sea tan alta siempre y cuando la distribución de falsos positivos o falsos negativos no sea perjudicial en la aplicación, como en este caso, puede que el algoritmo sea capaz de detectar con gran confiabilidad las mentiras, pero no las verdades.

Las redes neuronales probabilísticas presentan una certeza del 74 % y un coeficiente de Cohen's Kappa de 0.425, considerado moderado, en la categorización de segmentos de audio en verdad o mentira, utilizando indicadores psicométricos de la persona y mediciones de potencia en los segmentos de audio.

El algoritmo de k vecinos más cercanos presentó una certeza del 60.22 % con un $k = 19$ y distancia manhattan para la categorización de segmentos de audio en verdad o mentira.

Una implementación multi-hilo en un sistema de detección del engaño permite la ejecución segura y concurrente de diferentes módulos de detección, con la desventaja de que introduce restricciones para la seguridad en hilos.

Los análisis realizados no confirmaron la relación entre la Escala de Psicopatía de Hare (PCL-R) y las manifestaciones de engaño. Esto puede deberse a que los grupos de la prueba fueron poco homogéneos. Tampoco se encontraron efectos de la memoria de trabajo sobre las manifestaciones de engaño.

El sensor AF3 se activaba por el cortex prefrontal dorsolateral, encargado de la codificación, manipulación y selección de la memoria, las cuales son primordiales al momento de elaborar una mentira. Durante las pruebas, dicho sensor percibió variaciones de frecuencia en un rango de -1000mV a 2000 mV lo que apoyó la noción del rol que se percibe del proceso cognitivo, al momento de decir una mentira, de dicha área del cerebro.

La inclusión de los resultados de las pruebas psicométricas de Hare, Pebl y MSCEIT, de este último el CIEF, de mano con las señales electroencefalográficas en el conjunto de datos con el que se entrenó el algoritmo de aprendizaje supervisado (KNN) contribuyó a la producción de un modelo 19.5 % más preciso que sin estos resultados, siendo estos porcentajes de precisión 57.64 % y 76.14 % respectivamente. Sin embargo la precisión del modelo KNN para las predicciones en base a señales de electroencefalografía fue de 64.25 %

Los kernels empleados para Máquina de Vectores de Soporte fueron: Lineal, Polinomial y Gaussiano RBF. El mejor desempeño lo tuvo el modelo con kernel Gaussiano RBF. Este modelo tuvo un desempeño de precisión del cincuenta y ocho (58) por ciento para detectar el engaño. Sus mejores variables γ y C fueron $2^{-9.63}$ y 2^3 respectivamente.

Se logró implementar un programa que permite obtener los fotogramas de un video y procesarlos haciendo énfasis en las micro expresiones. Los puntos de referencia facial jugaron un papel muy

importante para obtener secciones específicas del rostro.

El etiquetado de los fotogramas fue de gran peso para encontrar patrones en los rostros de las personas, el etiquetado se baso en teoría de engaño de micro expresiones.

Se encontró que para tener un entrenamineto exitoso en redes neuronales convolucionales, con rostros de personas como entrada, se necesita una gran cantidad de imágenes de diferentes rostros, para que la red pueda encontrar mejores patrones en los rostros.

Al tener datos más específicas del rostro, la efectividad para poder encontrar indicios de engaño aumenta de forma considerable.

Para la grabación de los segmentos de audio utilizados para entrenar los algoritmos de aprendizaje de máquina fueron utilizados diferentes micrófonos con el objetivo de encontrar un modelo agnóstico a hardware, sin embargo, se recomienda experimentar utilizando un único micrófono y que éste sea de alta calidad.

A pesar de tener 900 muestras para entrenar los algoritmos de aprendizaje de máquina, es una cantidad minúscula si se compara con conjuntos de datos utilizados en los ejemplos de aprendizaje de máquina introductorios en internet, como MNIST que contiene 70,000 muestras. Debido a esto, se recomienda buscar estrategias para la recolección masiva de muestras al experimentar con aprendizaje de máquina.

Los algoritmos de aprendizaje de máquina poseen muchos parámetros que pueden ser variados con el objetivo de aumentar la certeza, por lo que se recomienda desarrollar una metodología de exploración automatizada para la variación y registro de éstos.

Para mejorar la calidad de la red neuronal se deberían utilizar más datos para el entrenamiento. Las pérdidas de datos a la larga afecta el desempeño de las redes.

Los programas utilizados para grabar los datos provistos por la herramienta Emotiv EPOC+, están escritos en la versión de Python 2.7, por tanto actualizar este programa a una versión más actualizada puede mejorar la compatibilidad y facilitar la integración con herramientas más modernas.

La normalización puede tener distintas repercusiones en los modelos generalmente acelera el proceso de predicción de los modelos, haciendo que estos produzcan mejores resultados. Sin embargo para KNN no fue el caso, es por eso que se recomienda utilizar otro tipo de normalización con este conjunto de datos, entre estas están las de características de escala o coeficientes de variación.

Características inusuales o que puedan segmentar de una mejor manera a la población objetivo, puede brindar un acercamiento distinto para la detección de sus emociones. Del mismo modo, escoger una población de estudio más amplia y general puede ayudar a representar de una mejor manera al ser humano como tal. Es decir, un mayor número de participantes y una mayor variabilidad en las características de estos puede ayudar a generalizar los elementos presentes en los seres humanos para la detección efectiva del engaño.

Realizar más entrevistas pero ampliar el tipo de población.

Analizar otros comportamientos como la dilatación de la pupila.

Se recomienda que se utilicen otras herramientas, Pygaze y Tobii eyetracker para hacer una mejor captura de los ojos.

Buscar una muestra más amplia para poder darle más validez a los datos de la investigación. Sobre todo, seguir el proceso de recolección de datos de forma meticulosa para evitar la pérdida de información valiosa.

Para la escala de psicopatía considerar un diseño experimental en base a entrevista estructurada o utilizar la versión de detección de la prueba PCL-SV, así como considerar expandir el estudio a otras poblaciones como bien podría ser la penitenciaría con el fin de evaluar también los perfiles más altos de la escala.

Al estudiar el engaño considerar las otras variables que puedan incidir en las respuestas registradas de los participantes. Estas variables del entorno o personales pueden incidir en los resultados, por lo que sería idóneo que futuras investigaciones puedan replicar el estudio considerando un ambiente más controlado para la prueba.

Expandir el análisis en cada facción de microexpresiones y/o cada electrodo, ya sea bien focalizando futuros estudios a medir el efecto de áreas específicas del rostro y/o de la actividad cerebral. Explorar otras áreas cerebrales más allá de la corteza prefrontal en la toma de medida con electrodos, especialmente aquellas que también guardan relación con la inteligencia emocional y la psicopatía que no se exploraron en este estudio, como el área del sistema límbico.

Para las pruebas psicométricas la exploración de manifestaciones del engaño en relación a los índices no utilizados en el presente estudio tanto para inteligencia emocional como la escala de psicopatía.

En cuanto a la parte de análisis de microexpresiones, para la grabación se recomienda, tener un objeto que salga en la cámara, para que de esta forma poder tomarlo como escala y obtener distancias más precisas en lugar de usar la distancia pupilar. Otro factor importante es pedirles a las personas que no muevan de forma brusca la cabeza, ni se la tapen al momento al momento de responder puesto que dificulta la captura de la expresión facial que tiene el entrevistado. Se debería también poder tener más entrevistas, con el fin de evaluar diferentes microexpresiones de las personas. Además de ello se recomienda también el uso de herramientas que permitan hacer el procesamiento de imágenes más rápido, con el fin de incluir muchas más capas y tener muchos más datos. Algo interesante sería poder obtener más datos del rostro, se podrían emplear el uso de herramientas como el Kinect, para tener profundidad del rostro y tener datos del movimiento del rostro. Con estos datos se podría llegar a mejorar bastante la eficiencia de los algoritmos, en especial el de redes neuronales convoluciones.

- Aggarwal, C. (2018). *Pattern Recognition and Image Preprocessing*. Cham: Springer Nature.
- Amen, D. (2011). *Cambia tu Cerebro Cambia tu Vida*. Editoriales Sirio.
- Bagwell, C. (2013). *SoX Documentation*. Descargado 2018-01-23, de <http://sox.sourceforge.net/sox.html>
- Belmonte, C. (2007). Emociones y cerebro. *Rev.R.Acad.Cienc.Exact.Fís.Nat. (Esp)*, 101(1), 59–68. Descargado de <http://www.rac.es/ficheros/doc/00472.pdf>
- Benjamin, A. (2014). *An Analysis of Overfitting in Particle Swarm Optimised Neural Network*. University of Pretoria.
- Berthold, M. R., Borgelt, C., Höppner, F., y Klawonn, F. (2010). *Guide to Intelligent Data Analysis: How to Intelligently Make Sense of Real Data*. Springer London. Descargado de <https://books.google.com.gt/books?id=EvGCsYe0FNwC>
- Boser, B. E., Guyon, I. M., y Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. En *Proceedings of the fifth annual workshop on computational learning theory - colt '92* (pp. 144–152). Descargado de <http://portal.acm.org/citation.cfm?doid=130385.130401> doi: 10.1145/130385.130401
- Bow, S. (2002). *Pattern Recognition and Image Preprocessing*. CRC Press.
- Byrnes, J. S., Hargreaves, K. A., y Berry, K. (2012). *Probabilistic and Stochastic Methods in Analysis, with Applications*. Springer Netherlands. Descargado de <https://books.google.com.gt/books?id=vnfwCAAAQBAJ>
- Camargo, C. . M. J., A.; Urrea. (s.f.). *Fundación Universitaria Los Libertadores*.
- Casella, G., Fienberg, S., y Olkin, I. (2006). *Springer Texts in Statistics* (Vol. 102). Descargado de <http://books.google.com/books?id=9tv0taI816YC> doi: 10.1016/j.peva.2007.06.006
- Chih-Wei Hsu, Chih-Chung Chang, y Lin, C.-J. (2008). A Practical Guide to Support Vector Classification. *BJU international*, 101(1), 1396–400. Descargado de <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf> doi: 10.1177/02632760022050997
- Chodorow, K. (2013). *MongoDB: The Definitive Guide: Powerful and Scalable Data Storage*. O'Reilly Media. Descargado de <https://books.google.com.gt/books?id=uGUKiNkKRJOC>
- Cloninger, S. (s.f.). *Teorías de la Personalidad*. Pearson Educación.
- Copestake, S. (2013). Emotional Intelligence and Psychopathy: A Comparison of Ability Measures. *Emotion*, 11.
- Davison, L. C. N. C. C. T. K. . Y. M. H., A. K. (2016). Objective Micro-Facial Movement Detection Using FACS-Based Regions and Baseline Evaluation. *Cornell University Library*,, 15-36.
- De Oliveira-Souza, H. R. B. I. G. G. A. F. T. F. M. J., R. (2008). Psychopathy as a disorder of

- the moral brain: Fronto-temporo-limbic grey matter reductions demonstrated by voxel-based morphometry. *Neuroimage*, 12.
- Dlib. (2018). *Dlib C++ Library*. Descargado 2 de Octubre de 2018, de <http://dlib.net/>
- Ekman, P. (2003). *Unmasking the face. A guide to recognizing emotions from facial clues*.
- Ekman, P. (2014). Porqué mienten los niños. *Barcelona: Paidós*.
- EPOC, E. (2003). Headset and software setup for your Emotiv EPOC neuroheadset. *SpringerReference*, 1–19. Descargado de http://www.springerreference.com/index/doi/10.1007/SpringerReference_28001 doi: 10.1007/SpringerReference_28001
- Erik G. (2014). Introduction to Supervised Learning. , 1–5. Descargado de <http://people.cs.umass.edu/~jelm/Teaching/Docs/supervised2014a.pdf>
- Etchepareborda, L., M; Abad-Mas. (s.f.). *Rev Neurol*.
- Fernandez, N; & Extremera, P. (2005). *La Inteligencia Emocional y la educación de las emociones desde el Modelo de Mayer y Salovey*. (R. I. d. F. del Profesorado, Ed.). Zaragoza. Descargado de <http://www.redalyc.org/articulo.oa?id=27411927005>
- Filipova, O. (2016). *Learning Vue.js 2*. Packt Publishing. Descargado de <https://books.google.com.gt/books?id=nszcDgAAQBAJ>
- Fletcher, T. (2009). Support Vector Machines Explained. [Online]. <http://sutikno.blog.undip.ac.id/files/2011/11/SVM-Explained.pdf>. [Abgerufen am: 04.01.2016], 1–19. Descargado de <http://sutikno.blog.undip.ac.id/files/2011/11/SVM-Explained.pdf> doi: 10.1002/9780470503065.app2
- Forth, A. (1996). The Assessment of Psychopathy in Male and Female Noncriminals: Reliability and Validity. *Personality Individual Differences*, 12.
- Gérard, A. (2011). El Sonograma: Una representación práctica de los sonidos. *Revista Boliviana de Física*(18), 37–49.
- Goleman, D. (2012). *Inteligencia Emocional*. Editorial Goleman.
- Grinberg, M. (2018). *Flask Web Development: Developing Web Applications with Python*. O'Reilly Media. Descargado de <https://books.google.com.gt/books?id=cV1PDwAAQBAJ>
- Guide, K. Q. (s.f.). KNIME Quickstart Guide Table of Contents Download one of the above versions , unzip it to any directory for which you have write Welcome Screen / Additional features When KNIME is started the first time a welcome screen opens . From here you can. , 1–25.
- Gutierrez, L. C. S., E; Duque. (2017). Emotion experience: Herramienta de Reconocimiento Facial para Medir la Experiencia del Usuario (UX) en niños a través de las Emociones. *Universidad de San Buenaventura, Cali*.
- Hassanat, A. B., Abbadi, M. A., y Alhasanat, A. A. (2014). Solving the Problem of the K Parameter in the KNN Classifier Using an Ensemble Learning Approach. , 12(8), 33–39.
- Hinton, G., Deng, L., Yu, D., Dahl, G., Mohamed, A., & Jaitly, N. e. (2012). Deep Neural Networksfor Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups. *IEEE Signal Processing Magazine*.
- Hope, T., Resheff, Y., & Lieder, I. (2017). *Learning TensorFlow: A Guide to Building Deep Learning Systems*. O'Reilly Media, Inc.
- Hurtig, B. (1988). *Multi-Track Recording: For Musicians*. California: Alfred Publishing Co.
- JBL. (s.f.). *Speaker Power Requirements, Answers to Often Asked Questions*. California: JBL Professional.
- Kataria, A., y Singh, M. D. (2013). A Review of Data Classification Using K-Nearest Neighbour Algorithm. *International Journal of Emerging Technology and Advanced Engineering*. doi: <http://dx.doi.org/10.1007/s10006-011-0288-3>
- Kosslyn, E. R. M., S; Smith. (2008). *Procesos Cognitivos: Funciones ejecutivas: modelos y bases neurales*.
- Kuhlman, D. (2012). A Python Book: Beginning Python, Advanced Python, and Python Exercises.
- Liu, Y. H. (2017). *Python Machine Learning By Example*. Packt Publishing Ltd.
- López, N. M., M. (2009). Psicopatía versus trastorno antisocial de la personalidad. *Revista Española de Investigación Criminológica*, 17.
- Masip, C., J; y Herrero. (s.f.).

- Papeles del Psicólogo.*
- Microsoft. (2018). *File types supported by Windows Media Player*. Descargado 2018-10-14, de <https://support.microsoft.com/en-us/help/316992/file-types-supported-by-windows-media-player>
- Niedermayer. (s.f.). *Electroencephalography: Basic principles, clinical applications, and related fields*. Lippincott Williams Wilkins.
- Palmero, F. (s.f.).
Revista electrónica de motivación y emoción.
- Pandey, A. (2017). Comparative Analysis of KNN Algorithm using Various Normalization Techniques. (November), 36–42. doi: 10.5815/ijcnis.2017.11.04
- Patterson, J., & Gibson, A. (2017). *Deep learning*. O'Reilly Media, Inc.
- Pham, H. (2006). *pyAudio Documentation*. Descargado 03/08/2018, de <https://people.csail.mit.edu/hubert/pyaudio/{#}docs>
- Portellano, J. (2005). *Introducción a las neurociencias*.
- Rai, R. (2013). *Socket. IO Real-Time Web Application Development*. Packt Publishing, Limited. Descargado de <https://books.google.com.gt/books?id=YgdbZbkTDkoC>
- Root, K. . L. D., P; Foster. (s.f.).
Neuroethics Publications.
- Rose, J. (2002). *Audio Postproduction for Digital Video*. CMP Books.
- Russell, S., & Norvig, P. (2009). *Artificial intelligence*. Upper Saddle River, N.J.: Prentice Hall.
- Shang, W., Sohn, K., Almeida, D., & Lee, H. (2016). Understanding and Improving Convolutional Neural Networks via Concatenated Rectified Linear Units. *Journal Of Machine Learning Research: Workshop And Conference Proceedings*.
- Sivanandam, S., Sumathi, S., & Deepa, S. (2017). *Introduction to neural networks using MATLAB 6.0* (T. M.-H. Education, Ed.). New Delhi.
- Suchotzki, B. B. B. B.-S. G. y. C. G., K.;Verschuere. (s.f.).
Department of Psychology, University of Würzburg.
- Team, G. D. R. (2006). A World of Lies. *J Cross Cult Psychol*, 37.
- Team, O. (2018). OpenCV library. Descargado de <https://opencv.org/>
- Tensorflow. (2018). *TensorFlow*. Descargado 2 de Octubre de 2018, de <https://www.tensorflow.org/>
- Van Honk, D., J.; Schutter. (s.f.).
- Venkatesan, R. (2018). *Convolutional Neural Networks in Visual Computing*.
- Vicianova, M. (2015). *Historical techniques of lie detection*. *Europe's Journal of Psychology* (Vol. 11) (n.º 3). Descargado de <https://doi.org/10.5964/ejop.v11i3.919>
- Vrij, A. (2000). *Detecting lies and deceit. The psychology of lying and the implications for professional practice*. Chichester:Wiley.
- Weiss, R. (2012). Scikit-learn : Machine Learning in Python Scikit-learn : Machine Learning in Python. (January).
- Winer, E. (2012). *The Audio Expert*. Focal Press.
- Wiseman, W. C. B. L. T. P. S. C. S. . R. C., R. (2012). The Eyes Don't Have It: Lie Detection and Neuro-Linguistic Programming. .
- Wu, J. (2012). *Advances in K-means Clustering: A Data Mining Thinking*.

CAPÍTULO 13

Anexos

Entrevistas

Para la recopilación de datos se utilizó la siguiente entrevista: PRIMERA PARTE (Verdad)

1. ¿Cuántos años tiene?
2. ¿Es casado/a?
3. ¿Le gusta a usted su trabajo/carrera?
4. ¿Habla usted otro idioma?
5. ¿Se considera usted una persona feliz?
6. ¿Cómo describiría su estado de salud actual?
7. ¿Con quién(es) vive? ¿Cómo describiría a su familia?
8. ¿Cómo se describiría a usted mismo?
9. ¿Ha consumido algún tipo de droga? ¿Cuál?
10. ¿Por qué escogió esa carrera/puesto?
11. ¿Qué lo motiva a trabajar/estudiar todos los días?
12. ¿Apoya usted la idea del aborto? ¿Por qué?
13. ¿Cuáles son sus planes a futuro?
14. ¿Por qué decidió colaborar con esta investigación?
15. Si el día de hoy le dieran medio millón de dólares, ¿qué haría con ellos?

SEGUNDA PARTE (Mentira)

1. ¿Cuántos años tiene?

2. ¿Es casado/a?
3. ¿Le gusta a usted su trabajo/carrera?
4. ¿Habla usted otro idioma?
5. ¿Se considera usted una persona feliz?
6. ¿Qué lo motiva a trabajar/estudiar todos los días?
7. Describa su rutina en una mañana normal
8. ¿Cuáles son sus planes a futuro?
9. ¿Apoya usted la idea del aborto? ¿Por qué?
10. ¿Cómo se describiría a usted mismo?
11. ¿Cuál es su mayor fortaleza?
12. ¿Ha consumido algún tipo de droga? ¿Cuál?
13. ¿Ha cometido algún delito grave alguna vez? ¿Cuál?
14. ¿Por qué decidió colaborar con esta investigación?
15. Si el día de hoy le dieran medio millón de dólares, ¿qué haría con ellos?

Para la prueba del sistema se realizó la siguiente entrevista: PRIMERA PARTE (Verdad):

1. ¿Cuántos años tiene?
2. ¿Con qué mano escribe?
3. ¿Trabaja Actualmente?
4. ¿Participó en la primera parte?

SEGUNDA PARTE (Situación Hipotética): Le vamos a hacer algunas preguntas que pueden o no aplicar a su vida. Si no aplican, siga el juego (o mienta)

1. Describa el delito que cometió el fin de semana
2. ¿Qué lo motivó a hacerlo?
3. ¿Cómo se sintió luego de hacerlo?
4. ¿Quiénes estaban con usted?
5. ¿Alguien más lo vio?
6. ¿Tuvo alguna consecuencia?
7. Se arrepiente de haberlo hecho?

Script de extracción de estadísticas utilizando SoX, Voz PNN

```
# PowerShell
foreach($file in Get-ChildItem .){
    echo $file.name >> stats.txt 2>&1;
    sox.exe $file.name n stats >> stats.txt 2>&1
}
```

Estructura de MongoDB — Ejemplo, Voz PNN

```
{
  "_id": ObjectId("5b7e056680e84119a0f8d5a3"),
  "pebl": 6,
  "dsmt": 50,
  "hare": 10,
  "ciep": 120,
  "cief": 108,
  "ciec": 114,
  "ciem": 90,
  "ciex": 116,
  "cies": 100,
  "cie": 108,
  "minLevel": -0.122437,
  "maxLevel": 0.173309,
  "pkLevel": -15.22,
  "rmsLevel": -36.68,
  "rmsPk": -24.44,
  "rmsTr": -52.04,
  "crest": 11.83,
  "label": "mentira"
}
```

Estructura de base de datos en Mysql para el módulo de señales de electroencefalografía

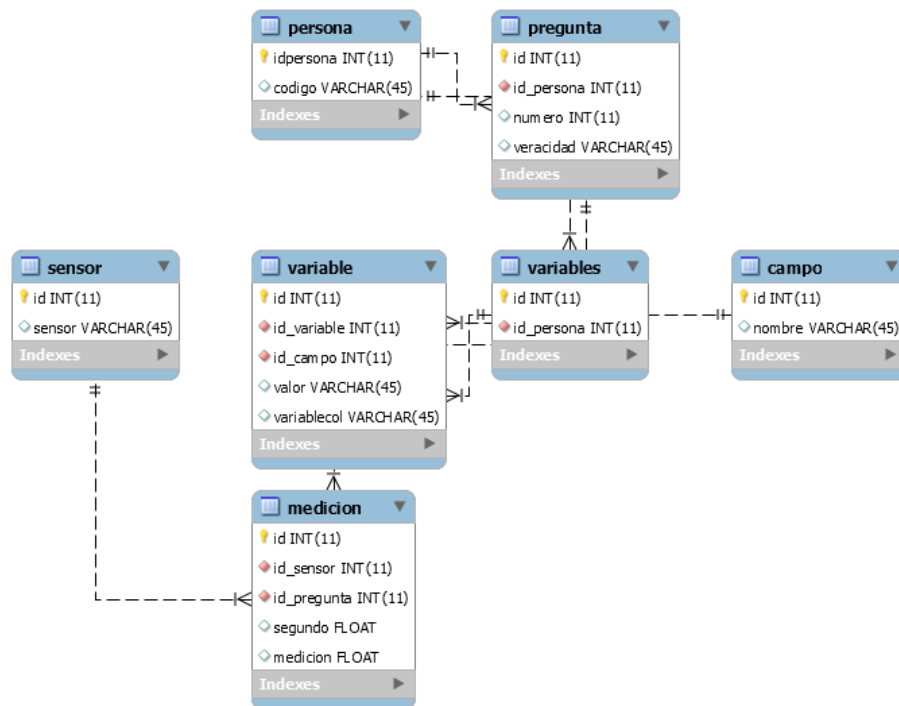


Figura D.1: Diagrama entidad-relación para el almacenamiento de los datos de señales EEG

Capturas de pantalla de herramienta

DETECCIÓN AUTOMATIZADA DEL ENGAÑO

Realizar prueba | Ayuda

ID: E007 Género: Masculino Edad: 22 PEBL: 6 DSMT: 50 HARE: 10 CIEP: 100 CIEF: 100
CIEC: 100 CIEM: 100 CIE: 100

Análisis de voz

- Olga
- Leonel
- Chan

Análisis de señales electroencefalográficas

- Koch
- Rudy
- Alvaro

Análisis de microexpresiones

- Castro
- Noriega

Iniciar pregunta

Figura E.1: Sistema en espera, listo para iniciar una pregunta



Figura E.2: Sistema grabando desde la cámara, micrófono y Emotiv.



Figura E.3: Sistema procesando la información y ejecutando los algoritmos de aprendizaje de máquina de cada módulo

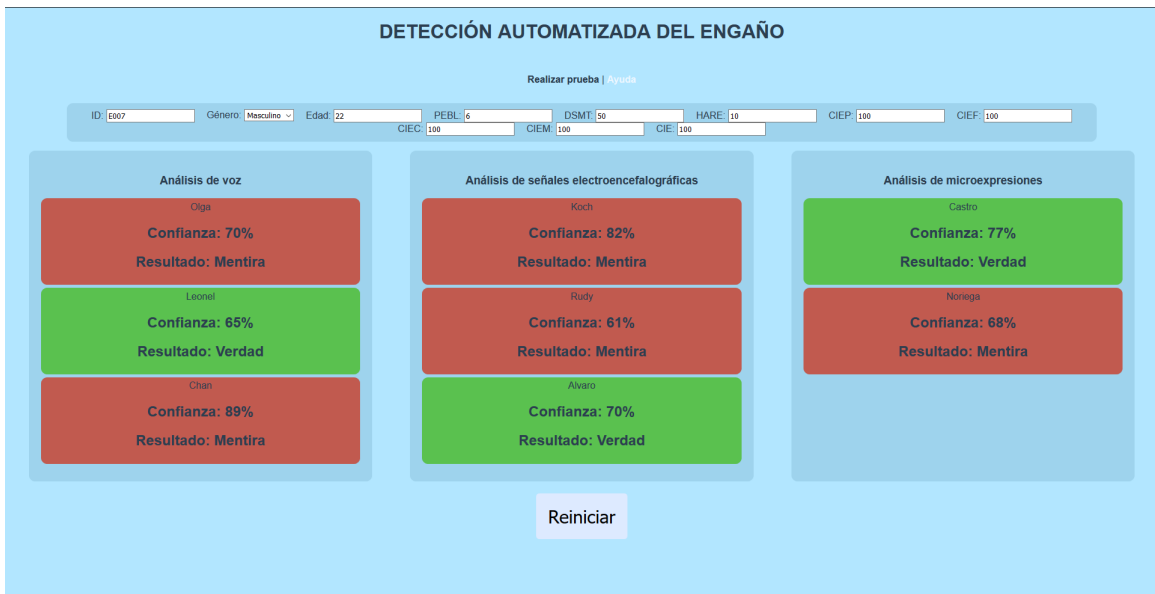


Figura E.4: Sistema reportando los resultados de cada módulo

Backend Software orientado a lógica, normalmente para servir las necesidades de frontends. 83, 84

Frontend Software orientado a vistas que interactúan con el usuario, normalmente utilizando información brindada por backends. 83, 84

Hardware Componentes físicos de una computadora. 83

Script Programa para automatizar la ejecución de tareas que podrían ser ejecutadas una a una por un humano. 39

Software Componentes lógicos de una computadora. 83

Lista de Símbolos

k Coeficiente de Cohen's Kappa