



Caracterización de los Potenciales Evocados Relacionados con Eventos Olfativos (OERP) provenientes del bulbo olfatorio en personas saludables empleando aprendizaje automático no supervisado.

Daniela Losada Cerquera

Universidad el Bosque
Facultad de Medicina
Bogotá, Colombia
2024

Caracterización de los Potenciales Evocados Relacionados con Eventos Olfativos (OERP) provenientes del bulbo olfatorio en personas saludables empleando aprendizaje automático no supervisado.

Daniela Losada Cerquera

Trabajo de grado presentado como requisito para optar al título de: **Magister en Informática Biomédica**

Director: Ph.D (C) Sistemas y Computación:
Andrés Cely Jiménez

Línea de Investigación:
Procesamiento de señales.

Universidad el Bosque
Facultad de Medicina
Bogotá D.C, Colombia
2024

A mi hermano

Mi compañero, amigo incondicional, apoyo, motivación y por supuesto eternamente el mejor hermano del mundo.

A mi abuelo

El ejemplo y legado de trabajo honesto y perseverancia, me enseñó a perseguir mis propósitos con determinación y pasión.

Los amo hasta el cielo.

Agradecimientos

A mis padres por su apoyo incondicional y confianza desde siempre, este proceso no sería posible sin ustedes, sin la motivación constante y sin el convencimiento de que todo es posible. Gracias por siempre hacerme sentir en casa un estado lejos.

A mi amado Jhon Freddy, por su infinita paciencia, comprensión, apoyo incondicional y motivación en mis momentos de mayor incertidumbre. Gracias al universo por coincidir contigo.

A mi directo de tesis Andrés Cely Jiménez, por la orientación en este proceso de investigación, por su compromiso, paciencia, disposición de tiempo y apoyo, siendo fundamental para el desarrollo de este proyecto.

1 Resumen

Las alteraciones olfativas y cognitivas se pueden identificar mediante la realización de test olfativos, los cuales se caracterizan en su mayoría por ser de tipo cualitativo. Numerosos estudios relacionan enfermedades neurodegenerativas y sistémicas graves con alteraciones en el olfato que se evidencian con mayor frecuencia en adultos mayores. El reto en el área de la salud es identificar marcadores preclínicos no invasivos que permita predecir mediante análisis de frecuencia y/o el tiempo de manera cuantitativa asociados a los eventos olfativos y sus alteraciones, por ello en esta investigación se plantea la implementación de aprendizaje computacional no supervisado *K-means* para la caracterización de los OERP en las señales electrobulbográficas (EBG) en el dominio del tiempo y en su densidad espectral (PSD *power spectral density*).

2 Abstract

Olfactory and cognitive alterations can be identified by means of olfactory tests, which are mostly qualitative. Numerous studies relate severe neurodegenerative and systemic diseases with olfactory alterations that are mostly evidenced in older adults. The challenge in the health area is to identify non-invasive preclinical markers that allow to predict by means of frequency and/or time analysis in a quantitative way associated with olfactory events and their alterations, therefore in this research we propose the implementation of unsupervised computational learning K-means for the characterization of the OERP in the electrobulbography signals (EBG) in the time domain and power spectral density (PSD).

3 Contenido

1	RESUMEN	4
2	ABSTRACT	6
3.1	LISTA DE FIGURAS.....	9
3.2	LISTA DE TABLAS	12
3.3	ANEXOS	13
3.4	INTRODUCCIÓN.....	14
3.5	PLANTEAMIENTO DEL PROBLEMA.....	15
3.6	JUSTIFICACIÓN	16
3.7	OBJETIVOS.....	17
3.7.1	<i>Objetivo general:</i>	17
3.7.2	<i>Objetivos específicos:</i>	17
3.8	HIPÓTESIS.....	17
4	MARCO TEÓRICO	18
4.1	OLFATO.....	18
4.1.1	<i>Bulbo olfativo</i>	18
4.2	BIOSEÑALES	19
4.2.1	<i>Electroencefalografía (EEG)</i>	19
4.2.2	<i>Electrobulbografía (EBG)</i>	20
4.3	POTENCIALES EVOCADOS	20
4.3.1	<i>Potenciales evocados olfatorios (OERP)</i>	20
4.4	PROCESAMIENTO DE BIOSEÑALES.....	20
4.4.1	<i>Procesamiento en el dominio del tiempo</i>	21
4.4.2	<i>Procesamiento en el dominio de la frecuencia</i>	21
4.5	APRENDIZAJE AUTOMÁTICO (ML).....	21
4.6	TIPO DE APRENDIZAJE AUTOMÁTICO.....	22
4.6.1	<i>Aprendizaje Supervisado</i>	22
4.6.2	<i>Aprendizaje no supervisado</i>	22
4.6.3	<i>Reducción de dimensionalidad</i>	24
4.7	APRENDIZAJE AUTOMÁTICO APLICADO AL PROCESAMIENTO DE SEÑALES	25
4.8	APRENDIZAJE AUTOMÁTICO EN SALUD	25
4.9	VALIDACIÓN DE ALGORITMOS DE APRENDIZAJE AUTOMÁTICO	26
4.9.1	<i>Índice de rad ajustado (ARI)</i>	26
4.9.2	<i>Información mutua normalización (NMI)</i>	26
4.9.3	<i>Índice Fowlkes- Mallows (FMI)</i>	26
4.9.4	<i>Medidas de calidad interna de los Clusters</i>	26
4.10	SITUACIÓN ACTUAL DEL ÁREA LA INVESTIGACIÓN	27
4.10.1	<i>Identificación de investigaciones en las que se implementó el uso de señales EEG</i>	27
4.10.2	<i>Identificación de investigaciones en las que se implementó el uso de señales EBG</i>	29
4.10.3	<i>Identificación bibliográfica de algoritmos de aprendizaje automático implementas en el procesamiento de señales</i>	30
4.10.4	<i>Identificación bibliográfica de algoritmos de aprendizaje automático implementas al análisis de señales olfatorias</i>	31
5	METODOLOGÍA	32
5.1	ENTENDIMIENTO DEL PROBLEMA	32

5.2	ENTENDIMIENTO DE LOS DATOS	33
5.3	PREPARACIÓN DE LOS DATOS	35
5.3.1	<i>Selección de olores a implementar</i>	35
5.4	LIMPIEZA DE LOS DATOS.....	37
5.4.1	<i>Integración y transformación de los datos</i>	38
5.5	MODELAMIENTO.....	39
5.6	EVALUACIÓN	40
5.7	DESPLIEGUE	40
5.8	RESULTADOS	44
5.8.1	<i>Respuesta a la hipótesis</i>	113
6	CONCLUSIONES.....	114
7	TRABAJOS FUTUROS.....	115
8	ANEXOS	115

3.1 Lista de Figuras

Ilustración 1. Representación gráfica del bulbo olfatorio, tomada de Fisiología humana (3ª. ed) (Tresguerres, 2005).	19
Ilustración 2. Componentes del modelo CRISP-DM, ciclo de vida de minería de datos tomado de IBM (IBM, 2021b).	32
Ilustración 3. Protocolo de adquisición de los datos (Sarmiento, 2024).	35
Ilustración 4. Distribución de electrodos estandarizada 10-20 en el cuero cabelludo, imagen tomada de (Carroble, 2016).	37
Ilustración 5. Diagrama de flujo correspondiente al procesamiento para la limpieza de los datos de señales EBG para la extrusión del OERP de la onda Theta en el dominio del tiempo.	38
Ilustración 6. Señales EEG onda Theta en el dominio del tiempo (x) – voltaje (y) correspondientes al OERP, aplicando técnicas de preparamiento para segmentación, eliminación del ruido e identificación de la onda Theta. ...	38
Ilustración 7. Extracción de la densidad espectral PSD, correspondiente a la onda Theta de señales EEG durante el OERP.	39
Ilustración 8. Software clasificador de OERP en la onda Theta. Indicaciones del proceso inicial, elección de estímulo olfativo y dominio en el que desea realizar la clasificación.	41
Ilustración 9. Software clasificador de OERP en la onda Theta. Indicaciones del proceso para el cargue del conjunto de datos a analizar e indicadores de cargue exitoso.	41
Ilustración 10. Software clasificador de OERP en la onda Theta. Indicaciones iniciar el proceso de clasificación por K.means.	42
Ilustración 11. Software clasificador de OERP en la onda Theta. Indicaciones restaurar el K.means en caso que se requiera y la habilitación de la sección de cargue de datos para realizar nuevas clasificaciones.	42
Ilustración 12. Software clasificador de OERP en la onda Theta. Indicador de las medias de calidad interna de los Clusters, la compacidad y la separabilidad respectivamente.	43
Ilustración 13. Software clasificador de OERP en la onda Theta, En la sección “Clasificador señal(t) OERP” se observará la gráfica de previsualización de la señal en el dominio del tiempo.	43
Ilustración 14. Proceso de caracterización de señales.	44
Ilustración 15. Señal en el dominio del tiempo proveniente de los canales Fp1, Fp2 y Fpz en la onda Theta antes de la presentación del estímulo olfativo y durante el OERP como.	45
Ilustración 16. Grafica correspondiente a la media de las señales provenientes de los 10 sujetos en olor a Ajo de onda Theta a los canales Fp1, Fp2 y Fpz durante 1 segundo, representándose la señal en reposo en color azul y la señal del OERP en color rojo.	46
Ilustración 17. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a ajo para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz [-0,05 0,05] μV , Fp1 [-0,05 0,05] μV y Fp2 [-0,05 0,05] μV .	47
Ilustración 18. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a canela para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud, observándose predominancia en Fpz [-0,05 0,05] μV , Fp1 [-0,05 0,05] μV y Fp2 [-0,05 0,05] μV .	48
Ilustración 19. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a limón para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz [-0,05 0,05] μV , Fp1 [-0,05 0,05] μV y Fp2 [-0,05 0,05] μV .	49
Ilustración 20. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a manzana para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz [-0,05 0,05] μV , Fp1 [-0,05 0,05] μV y Fp2 [-0,05 0,05] μV .	50
Ilustración 21. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a menta para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz [-0,05 0,05] μV , Fp1 [-0,05 0,05] μV y Fp2 [-0,05 0,05] μV .	51

Ilustración 22. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a naranja para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.	52
Ilustración 23. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a Trementina para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.	53
Ilustración 24. PSD Fp1 correspondiente a 10 sujetos durante el OERP de olfacción Ajo.	54
Ilustración 25. PSD Fp2 correspondiente a 10 sujetos durante el OERP de olfacción Ajo.	55
Ilustración 26. PSD Fpz correspondiente a 10 sujetos durante el OERP de olfacción Ajo.	56
Ilustración 27. Diagrama de cajas y bigotes de la frecuencia máxima en el punto mas alto de potencia para Fp1, Fp2 y Fpz en el olor a Ajo.	57
Ilustración 28. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Canela.	60
Ilustración 29. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Canela.	61
Ilustración 30. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Canela.	62
Ilustración 31. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Canela.	63
Ilustración 32. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Limón.	66
Ilustración 33. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Limón.	67
Ilustración 34. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Limón.	68
Ilustración 35. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Limón.	69
Ilustración 36. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Manzana.	71
Ilustración 37. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Manzana.	72
Ilustración 38. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Manzana.	73
Ilustración 39. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Manzana.	74
Ilustración 40. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Menta.	77
Ilustración 41. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Menta.	78
Ilustración 42. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Menta.	79
Ilustración 43. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Menta.	80
Ilustración 44. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Naranja.	83
Ilustración 45. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Naranja.	84
Ilustración 46. PSD Fpz correspondiente a 10 sujetos durante el OERP ritmo Theta de olfacción Naranja.	85
Ilustración 47. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Naranja.	86
Ilustración 48. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Trementina.	89
Ilustración 49. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Trementina.	90
Ilustración 50. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Trementina.	91
Ilustración 51. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Trementina.	92
Ilustración 52. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1 en el olor a Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.	94
Ilustración 53. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp2 en el olor a Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.	95
Ilustración 54. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fpz en el olor a Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.	96
Ilustración 55. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Ajo.	97
Ilustración 56. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Canela.	98
Ilustración 57. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Limón.	99

Ilustración 58. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Menta.	100
Ilustración 59. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Manzana.	101
Ilustración 60. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Naranja.	102
Ilustración 61. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Trementina.	103
Ilustración 62. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Ajo.	104
Ilustración 63. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Canela.	105
Ilustración 64. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Limón.	106
Ilustración 65. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Menta.	107
Ilustración 66. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Manzana.	108
Ilustración 67. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Naranja.	109
Ilustración 68. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Trementina.	110
Ilustración 69. K-means correspondiente de la señal resultante del procesamiento de la señal de PSD de 10 sujetos, usando para la señal proveniente de Fp1, Fp2 y Fpz, en los olores a Ajo, Canela, Limón, Manzana, Mental, Naranja, Trementina.	111
Ilustración 70. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, usando para la señal proveniente de Fp1, Fp2 y Fpz, en los olores a Ajo, Canela, Limón, Manzana, Mental, Naranja, Trementina.	112

3.2 Lista de Tablas

Tabla 1. Revisión bibliográfica aprendizaje supervisado.....	22
Tabla 2. Revisión bibliográfica aprendizaje no supervisado.....	24
Tabla 3. Revisión bibliográfica reducción dimensional.....	25
Tabla 4. Identificación de investigaciones en las que se implementó el uso de señales EEG.....	28
Tabla 5. Identificación de investigaciones en las que se implementó el uso de señales EBG.....	29
Tabla 6. Identificación bibliográfica de algoritmos de aprendizaje automático implementas en el procesamiento de señales.....	30
Tabla 7. Identificación bibliográfica de algoritmos de aprendizaje automático implementas al análisis de señales olfatorias.....	31
Tabla 8. Descripción de la base de datos “Diagnostico diferencial de síndromes demenciales para el reconocimiento de Alzheimer en personas con déficit cognitivo leve: potenciales biomarcadores de señales EEG”.....	34
Tabla 9. Revisión bibliográfica de olores usados investigaciones relacionadas con procesamiento de señales.....	36
Tabla 10. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a ajo, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.....	57
Tabla 11 Medidas de tendencia central durante OERP del ritmo Theta de olfacción a canela, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.....	63
Tabla 12. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a Limón, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.....	69
Tabla 13. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a manzana, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.....	74
Tabla 14 Medidas de tendencia central durante OERP del ritmo Theta de olfacción a menta, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.....	80
Tabla 15. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a naranja, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.....	86
Tabla 16. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a Trementina, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.....	92
Tabla 17. Valor de compacidad y separabilidad correspondiente al K-means de los 7 olores en el dominio del tiempo para los canales Fp1, Fp2 y Fpz.....	113
Tabla 18. Valor de compacidad y separabilidad correspondiente al K-means de los 7 olores en el PSD para los canales Fp1, Fp2 y Fpz.....	113

3.3 Anexos

Anexo 1. Código fuente para el procesamiento, segmentación, y extracción de características en el dominio del tiempo y la frecuencia.	133
Anexo 2. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a ajo, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.	133
Anexo 3. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a canela, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.	134
Anexo 4. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a limón, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.	134
Anexo 5. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a manzana, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.	135
Anexo 6. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a menta, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.	135
Anexo 7. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a naranja, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.	136
Anexo 8 Medidas de tendencia central durante OERP del ritmo Theta de olfacción a trementina, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.	136

3.4 Introducción

La implementación de las tecnologías emergentes permite y apoya los desarrollos tecnológicos al área de la salud, estableciéndose así el uso de nuevas técnicas computacionales como una nueva herramienta con capacidades para la obtención de nuevo conocimiento.

Las técnicas de procesamiento de señales permiten la extracción de características como la amplitud de la señal, la frecuencia, la densidad espectral, entre otras, identificándose patrones que son usados como apoyo diagnóstico de enfermedades.

El procesamiento y análisis de la electrobulbografía EBG podría establecer un método de diagnóstico cuantitativo no invasivo para identificar alteraciones olfativas y/o neurodegenerativas, el uso de aprendizaje computacional en este caso el uso del método *K-means* permite la agrupación de los datos facilitando identificar con mayor exactitud los patrones provenientes de las bioseñales, obteniendo agilidad, desarrollo eficaz y oportuno en el campo de la biomédica.

3.5 Planteamiento del problema

El diagnóstico de enfermedades olfativas tiende a ser subjetivo, como lo son la implementación de test olfativos estandarizados los cuales se diagnostican a través de métodos cualitativos entre ellos podemos encontrar el test de olores *Sniffin Sticks*, el COLT (*California Odor Learning Test*), el UPSIT (*University of Pennsylvania Smell Identification Test*)(Chacón Martínez et al., 2005), entre otros avalados en habla inglesa, hispana y portuguesa(Chacón Martínez et al., 2005; Fornazieri et al., 2010; Hummel et al., 2007; Kobal et al., 2000; Ribeiro et al., 2016). En la actualidad uno de los grandes desafíos es mejorar la precisión en el diagnóstico preclínico para la toma de decisiones, para esto se implementan técnicas de imágenes como tomografía computacional (TC) y resonancia magnética funcional (RMf)(Carrillo et al., 2017; Chacón Martínez et al., 2005; Fulbright et al., 1998; Masaoka et al., 2014). Éstas ofrecen una alta resolución espacial pero una baja resolución temporal (Chacón Martínez et al., 2005; Walla et al., 2011).

Las alteraciones olfativas pueden ser multifactoriales como daño en I par craneal, obstrucción en los senos paranasales, también se ha encontrado una relación entre las alteraciones olfativas con enfermedades graves(Chaná & Júri, 2007; Cofré et al., 2015; Rahayel et al., 2012^a; Robles-Osorio et al., 2020)incluyendo neurodegenerativas como el deterioro cognitivo leve (DLC)(Walla et al., 2011), Alzheimer(Quarmley et al., 2017; Wen et al., 2020) , Parkinson(Bonfils, 2008; Rahayel et al., 2012b), cáncer, diabetes, entre otras (Cofré et al., 2015) .

A partir de la necesidad de plantear nuevos métodos de test de olfacción que sean cuantitativos, se propone un análisis de señales EBG (Electrobulbografica) usando aprendizaje automático no supervisado que permita identificar, cuantificar y caracterizar los *OERP* (olfactory event-related potential) correspondientes. Ya que la subjetividad y los altos costos de los exámenes que presentan una buena resolución espacial no facilita el diagnóstico preclínico de enfermedades graves de manera oportuna y de forma no invasiva.

3.6 Justificación

Esta investigación surge ante la necesidad de cuantificar y caracterizar el comportamiento eléctrico del bulbo olfatorio para el apoyo diagnóstico, dado que los test olfativos en su mayoría son cualitativos y se tornan subjetivos. En el 2020 el mundo atravesó por una crisis sanitaria dado la declaración de pandemia debido al COVID-19 (Organización Panamericana de la Salud, 2020), dentro de la sintomatología y efectos secundarios provocados por esta enfermedad se encuentra la alteración olfativa (Alfaro et al., 2020; Moein et al., 2020) . Por lo tanto, se encuentra pertinente el estudio del olfato, ya que las alteraciones olfativas en múltiples estudios son consideradas como síntoma a mediano y/o largo plazo de enfermedades graves como lo son las enfermedades neurodegenerativas. Por lo tanto, esta investigación busca contribuir mediante la cuantificación y caracterización de las señales EBG de forma no invasiva en personas sin alteraciones olfativas y que esto permita obtener una línea de base en relación con el comportamiento de las señales electrobulbográficas normales.

3.7 Objetivos

3.7.1 Objetivo general:

- Caracterizar los *ERP* olfativos por medio de algoritmo de aprendizaje automático no supervisado, que permita identificar el comportamiento en las señales EBG de forma cuantitativa en personas saludables.

3.7.2 Objetivos específicos:

- Implementar algoritmo de aprendizaje computacional no supervisado en las señales EBG provenientes de bases de datos públicas.
- Determinar el efecto de la variación de las señales EBG identificando el efecto diferencial distintivo y correspondientes a los *ERP* olfativos de la exposición y reconocimiento de cada uno de los olores.
- Desarrollar software que permita la Caracterización de los Potenciales Evocados Relacionados con Eventos Olfativos (*OERP*) provenientes del bulbo olfatorio en personas saludables empleando aprendizaje automático no supervisado.

3.8 Hipótesis

Es posible caracterizar los ERP olfativos producidos por el bulbo olfatorio durante la presentación de estímulo olfativo mediante señales electrobulbográficas empleando aprendizaje computacional no supervisado.

4 Marco Teórico

La aplicación y el uso de las ciencias aplicadas al área de la salud han permitido el desarrollo de tecnología que ha contribuido a la evolución del estudio y análisis funcional del cuerpo humano y sus sentidos, apoyando así diagnósticos con mayor precisión. El uso de nuevas tecnologías basadas en mecanismos de aprendizaje automático permite la generación de nuevas técnicas de apoyo a la toma de decisiones clínicas diagnósticas basadas en datos.

4.1 Olfato

El sentido del olfato se puede clasificar como quimiorreceptor y telerreceptor debido a la energía química del estímulo y su detección distante. El sistema olfatorio está conformado por neuronas sensoriales llamadas receptores olfativos que están ubicados en la mucosa de cada fosa nasal, conformando así, con sus axones el I par craneal (nervio olfativo), cruzando el hueso etmoides, finaliza realizando sinapsis en los bulbos olfatorios. (Tresguerres, 2005).

4.1.1 Bulbo olfativo

La estructura del bulbo olfatorio está formada por múltiples capas de células y núcleos que se encuentran situados en la base cerebral, siendo elemental en el proceso de olfacción. Debido a que procesa y/o transmite información olfativa mediante la actividad eléctrica desde los receptores de la nariz hasta la corteza superior del cerebro que está vinculada con el procesamiento olfatorio. (J. A. F. Tresguerres et al., 2005; Freddy Enrique, 2023; Izquierdo-Domínguez et al., 2020; Nagayama et al., 2014).

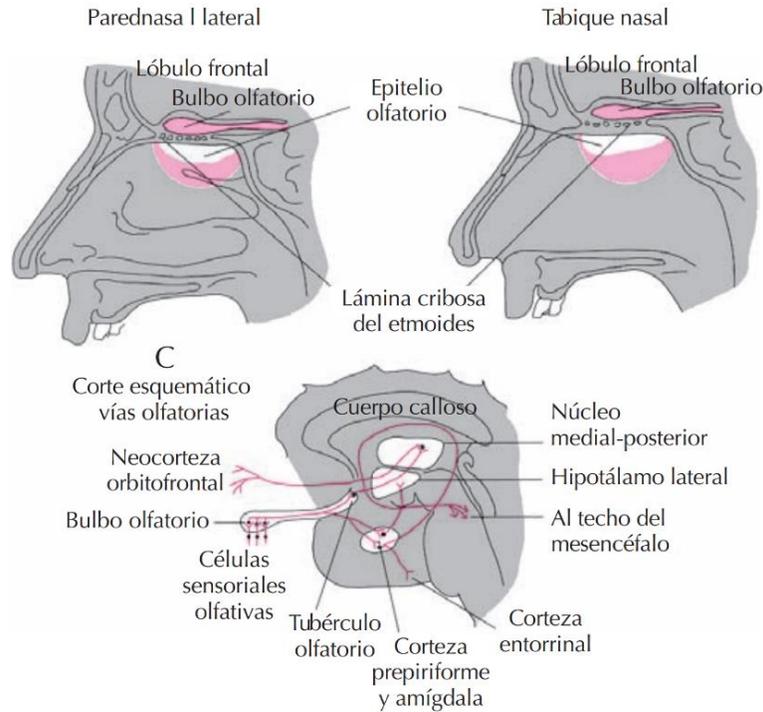


Ilustración 1. Representación gráfica del bulbo olfatorio, tomada de *Fisiología humana* (3ª. ed) (Tresguerres, 2005).

4.2 Bioseñales

Las bioseñales son un medio por el cual se transmite información, su adquisición y análisis permite extraer información de los sistemas fisiológicos y su funcionamiento, apoyando así el diagnóstico y el criterio médico. Los biopotenciales corresponden a la actividad electroquímica producidas por las células, esta actividad eléctrica se denomina según su origen fisiológico, puesto que cada tipo de célula presenta su actividad eléctrica característica, entre ellas se encuentran las señales Electroencefalográficas (EEG) (Gómez-Díaz et al., 2018a; Guerrero Martínez, 2010; Subasi, 2019; Tran, 2020).

4.2.1 Electroencefalografía (EEG)

Implementando un galvanómetro y dos electros en la piel del cuero cabelludo de un sujeto se registró por primera vez en 1875 la actividad eléctrica cerebral, identificándose así señales no lineales y estocásticas resultantes del estímulo sináptico, en respuesta al bombeo de iones de sodio positivo Na^+ , Potasio K^+ , calcio Ca^{2+} , y un ion negativo de cloro Cl^- mediante membranas neuronales moderado por el potencial de membrana. Las señales EEG oscilan entre $5\mu\text{V}$ y $300\mu\text{V}$ (Losada, 2020; Sanei & Chambers, 2007)(Losada, 2020; Sanei & Chambers, 2007).

4.2.2 Electrobulbografía (EBG)

El bulbo olfatorio se encuentra ubicado en la base del cerebro, por lo tanto, la electrobulbografía EBG hace parte de las señales EEG, Las señales EBG es un término nuevo que surge en el 2020 y hace referencia a las señales eléctricas que provienen del bulbo olfatorio, para la adquisición de estas señales se localizan dos electrodos a cada lado del puente nasal, encima de las cejas, observándose la sincronización relacionada con eventos de olores (*OERP*) (Iravani et al., 2020a).

4.3 Potenciales evocados

Son producto de un estímulo sensorial controlado, pero que además se relacionan con procesos psicológicos internos que han sido disparados directamente por un estímulo externo o indirectamente por un estímulo interno y que son producto del procesamiento cerebral debido al estímulo (Kamel & Malik, 2015; Muñoz Gamboa & Jiménez Cruz, 2008).

4.3.1 Potenciales evocados olfatorios (*OERP*)

Consiste en la recogida de la actividad eléctrica (del bulbo olfatorio y/o la corteza frontal) mediante electrodos externos mientras se aplican estímulos olfativos. Para un registro de calidad deben estabilizarse la temperatura de la habitación, la humedad del aire y los estímulos (deben aplicarse cada 30-45 s), para superar la dificultad de detectar una señal muy leve (Izquierdo-Domínguez et al., 2020; Kamel & Malik, 2015; Pause et al., 1996).

Las señales EBG y las bioseñales en general están obtenidas en unidad de medida de microvoltios μV , por lo tanto se produce el surgimiento de la procesamiento digital de señales, siendo una ciencia de la ingeniería que implementa múltiples técnicas para el análisis y la extracción de características implícitas y explícitas de las señales ya sean en el dominio del tiempo, tiempo frecuencia, densidad espectral, mediciones de la entropía de la señal, del tiempo, espectral, multiresolución, análisis estadísticos, entre otros (Gómez-Díaz et al., 2018b; Noelia & Cicchino, 2013).

4.4 Procesamiento de bioseñales

El procesamiento de bioseñales permite la extracción de información útil y de importancia como el reconocimiento de patrones, de potenciales evocados y eventos de importancia, además permite el monitoreo de la salud, diagnóstico de enfermedades, verificar el estado fisiológico, adicionalmente permite interacciones interfaz cerebro computador, sistemas de control y dispositivos médicos, entre otros (Najarian, n.d.; Tompkins, 2000).

4.4.1 Procesamiento en el dominio del tiempo

Es una técnica utilizada que permite analizar los datos provenientes de una señal original mediante su manipulación y análisis, centrándose en cómo cambia los valores de la señal en la longitud de tiempo. Algunas de las técnicas que implementan son la aplicación de filtros que permite la eliminación de ruido y/o componentes no deseados, detección de eventos y picos, análisis de tendencia. Así mismo como la segmentación temporal que permite un análisis detallado y cálculo de características temporales como extracción de la media, desviación estándar, entre otras (Najarian, n.d.) .

4.4.2 Procesamiento en el dominio de la frecuencia

Esta técnica implica manipulación y análisis de las características espectrales provenientes de la señal, centrándose en la distribución de frecuencia en la señal. Para el análisis de bioseñales comúnmente se implementa la transformada rápida de Fourier, permitiendo así convertir la señal del dominio del tiempo al dominio de la frecuencia, permitiendo identificar patrones, frecuencias dominantes, entre otros (Najarian, n.d.; Tompkins, 2000).

Entre el análisis de frecuencia se encuentra la densidad espectral *PSD*, siendo una herramienta fundamental en análisis de señales proporcionando información de la distribución de energía de la señal en diferentes frecuencias, indicando la potencia existe en cada frecuencia que compone la señal, siendo de gran utilidad para identificación de componentes frecuenciales importantes, usándose para caracterizar la naturaleza estocástica de la señal (Stoica & Moses, 2005).

4.5 Aprendizaje automático (ML)

Es la ciencia de programación computacional con capacidad de aprender sin programación explícita y a partir de los datos, basado en la experiencia con respecto a la tarea asignada (Jorge Díaz-Ramírez, 2021).

4.6 Tipo de aprendizaje automático

4.6.1 Aprendizaje Supervisado

Mecanismos de aprendizaje que necesita conocimiento previo o de una etiqueta que indique el valor de salida que debería tener nuestra muestra, a esta etiqueta se le conoce como *ground truth* (GT). Por lo tanto, la meta del aprendizaje supervisado es encontrar una función que, dada una muestra de datos de entrenamiento y sus respectivas etiquetas GT (Pablo Antonio Stack Sánchez, 2021).

Algoritmo	Características	Referencias de uso
SVM (<i>Support Vector Machine</i>)	Algoritmo implementado en problemas clasificación y regresión, con el fin de encontrar el hiperplano de secuenciación delimitando las clases.	“Sistema de clasificación SVM de señales electromiográficas extraídas en un sistema embebido”(Daniel et al., 2019)
Aprendizaje basado en kernels (<i>Kernel-based Learning</i>)	El entrenamiento de este algoritmo se especializa en la extracción de características no lineales.	"Análisis de Señales Biomédicas para Aplicación de Terapias en la Fibrilación Ventricular Cardíaca”(Mjahad, 2017)

Tabla 1. Revisión bibliográfica aprendizaje supervisado.

4.6.2 Aprendizaje no supervisado

Es un tipo de algoritmo que mediante la identificación automática de datos sin etiquetas que se usan para identificar y aprender por sí mismo las características implícitas de las tareas asignadas (Pablo Antonio Stack Sánchez, 2021) .

Algoritmo	Características	Referencias de uso
<i>K-means</i>	Agrupación Divide los datos en <i>K clusters</i> , donde K es un número predefinido. Asigna cada dato al cluster más cercano en función de la distancia euclidiana(Han et al., 2011a) .	“Selección de Electrodo Basada en k-means para la Clasificación de Actividad Motora en EEG”(Lemuz-López et al., 2014).
<i>Clustering jerárquico</i>	Construye una jerarquía de clusters en la que los clusters más pequeños se combinan gradualmente en clusters más grandes (Han et al., 2011a) .	"Análisis de Señales Biomédicas para Aplicación de Terapias en la Fibrilación Ventricular Cardíaca”(Mjahad, 2017).
DBSCAN (<i>Density-Based Spatial Clustering of Applications with Noise</i>)	Identifica clusters basados en la densidad de puntos en el espacio de características(Berkhin, 2006; Han et al., 2011a).	“ <i>A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise</i> ”(Ester et al., 1996).
<i>Mean-Shift</i>	Es un método que ejecuta usando la distribución de probabilidad estadística encontrando <i>clusters</i> al mover un kernel en el espacio de datos hacia las regiones de mayor densidad de puntos (Berkhin, 2006; Han et al., 2011a) .	“Diagnóstico de Señales Biomédicas con Redes Neuronales Artificiales”(Medina, 2015).

Clustering espectral	Implementa la información espectral de la matriz de similitud para agrupar los datos (Berkhin, 2006; Han et al., 2011a).	“Nuevos desarrollos y aplicaciones basados en métodos estocásticos para el agrupamiento no supervisado de latidos en señales electrocardiográficas”(Micó, 2005).
----------------------	--	--

Tabla 2. Revisión bibliográfica aprendizaje no supervisado.

4.6.3 Reducción de dimensionalidad

Las reglas asociativas son patrones de relación entre diferentes elementos en un conjunto de datos, esto indica que la presencia de los registros está asociada con la pertenencia de otros elementos(Han et al., 2011b) .

Algoritmo	Características	Referencias de uso
PCA (<i>Principal Component Analysis</i>)	Reducción de dimensionalidad y agrupamiento espectral, estos métodos procuran realiza y/o encontrar agrupaciones en el subespacio entre los datos originales, en algunos casos es más poderoso contrayendo nuevos espacios en lugar de implementar la subestación dados por los datos originales(Han et al., 2011b) .	“Clasificación de señales EMG”(Meza, n.d.).
LLE (Embebido de Vecinos Locales)	Técnica no lineal que representa la relación en el espacio entre los puntos en alta y baja densidad.	“Procesamiento Embebido de P300 Basado en Red Neuronal Convolutacional para Interfaz Cerebro-Computadora Ubicua”(Jose & Juan Ramirez, 2020).

LDA (Análisis Discriminante Lineal)	Optimiza la separación de clases en el espacio de menor dimensión, disminuyendo la varianza en las clases.	“Clasificación de señales de electroencefalograma para diagnosticar depresión”(Guevara, 2016).
-------------------------------------	--	--

Tabla 3. Revisión bibliográfica reducción dimensional.

4.7 Aprendizaje automático aplicado al procesamiento de señales

En la aplicación del aprendizaje automático, el mundo del procesamiento de señales biomédica, se han desarrollado investigaciones, incluso el desarrollado de predicciones de fracaso escolar a partir de señales EEG usando un algoritmo K- Vecinos cercanos KNN (M. A. Rasheed et al., 2021) identificación de anomalías en las señales EEG empleando redes neuronales convolucionales (CNN) y recurrentes (LSTM) (Albaqami et al., 2023), reconocimiento de depresión mediante la ejecución de EEGNet siendo redes neuronales convolucionales (Liu et al., 2022), predicción de ataques epilépticos según lo mencionado en revisiones (K. Rasheed et al., 2020), detección de patologías en señales de electrocardiografía usando un enfoque bayesiano (Lorena et al., 2020), entre otras aplicaciones.

4.8 Aprendizaje automático en salud

El uso de aprendizaje automático en el área de la salud ha revolucionado incluyendo los sistemas de información en salud, identificación de factores de riesgo de enfermedades graves, predicción de muerte intrahospitalaria, implementación de leguaje natural en la generación de texto facilitando así la redacción de notas e historia clínicas (Aracena et al., 2022), apoyo diagnóstico de enfermedades mediante la clasificación de imágenes médicas usando algoritmos de aprendizaje automático de código abierto como lo son *TensorFlow*, *Pytorch*, *Keras* y *Caffe*; desarrollos de software en función de métodos de aprendizaje profundo en el apoyo diagnóstico de COVID-19 mediante el análisis de imágenes médicas; redes neuronales convolucionales como soporte asistencial en la adquisidor de imágenes ecocardiográficas (Ávila-Tomás et al., 2021; Fernández, 2019; Galván et al., 2022; Loncaric et al., 2021). Además, soporta sistemas epidemiológicos con mayor precisión y georreferenciados mediante la implementación de redes neuronales artificiales

en conjunto con software ArcGIS (Mazzola, 2021). Entre otras múltiples intervenciones que han aportado mejoras en la calidad en los procesos de salud.

4.9 Validación de algoritmos de aprendizaje automático

Durante el proceso de evolución y/o validación de algoritmos de aprendizaje automático, se verifica el rendimiento del modelo, la precisión y confiabilidad de este, garantizando la idoneidad del algoritmo en la tarea determinada (Rand, 1971), algunos métodos que se emplean son los siguientes:

4.9.1 Índice de rad ajustado (*ARI*)

Mediante la implementación del método *ARI*, se realiza la validación de precisión del algoritmo de aprendizaje automático, determinada mediante la medición de similitud entre dos agrupaciones tomando en cuenta todos los pares de puntos y clasificación. Su rango de medición está determinado entre $[-1, 1]$ donde 1 representa concordancia, 0 concordancia al azar y -1 discordancia total (Xuan Vinh et al., 2010).

4.9.2 Información mutua normalización (*NMI*)

Esta técnica de validación se coincide externa ya que requiere las respectivas etiquetas de clases para determinar la medición entre dos grupos. La ejecución del método *NMI*, realiza la medición de la información mutua entre dos grupos permitiendo caracterizar la calidad de la agrupación (Xuan Vinh et al., 2010).

4.9.3 Índice Fowlkes- Mallows (*FMI*)

Este modelo de evaluación es considerando como evaluación externa, definiendo así la proporción de pares de puntos pertenecientes al mismo agrupamiento; y la proporción de pares pertenecientes a diferentes agrupamientos. Su rango de medición está dado entre $[0, 1]$ donde 1 representa perfecta concordancia y 0 discordancia total (Vilela Junior et al., 2022).

4.9.4 Medidas de calidad interna de los Clusters

Hace referencia a la cohesión y separación de los grupos dentro de un conjunto de datos, Esta medida que indica que tan definidos están los clusters y la distribución de sus puntos(Jain et al., 2000).

4.10 Situación actual del área la investigación

A través del tiempo, el estudio y análisis de las señales EEG en procesos olfatorio se ha incrementado, la siguiente tabla nos permite identificar el nombre del artículo, tipo de acceso a los datos, tipo de procesamiento implementado y resultados, aportes, olores usados entre otros datos a resaltar de cada investigación.

4.10.1 Identificación de investigaciones en las que se implementó el uso de señales EEG

<i>Artículo</i>	<i>Datos</i>	<i>Procesamiento</i>	<i>Opinión</i>
Electroencephalographic Response to Different Odors in Healthy Individuals: A Promising Tool for Objective Assessment of Olfactory Disorders(Krbot Skorić et al., 2015a) .	Privados	Algoritmo FFT.	Para menta y limón, $F(1.576, 23.637) = 16.030$, $P = .000$ y $F(1.362, 20.425) = 4.54$, $P = .035$, respectivamente, no presento diferencias estadísticamente significativas para la vainilla entre áreas específicas, $F(1.217, 18.257) = 1.155$, $P = .309$.
“Time frequency analysis of olfactory induced EEG-power change”(Schriever et al., 2017).	Privados	Algoritmo PSD.	Fue posible distinguir de manera confiable a los pacientes con deterioro olfativo de los individuos sanos con un alto grado de precisión (controles sanos frente a pacientes anósmicos: sensibilidad 75%; especificidad

			89%)
“ <i>Human electroencephalographic EEG. Response to olfactory stimulation: Two experiments using the aroma of food</i> ” (Martin, 1998a).	Privados	Algoritmo FFT.	La exposición al olor del chocolate y menta verde se asoció con reducciones significativas en la actividad theta.
“ <i>Olfaction Recognition by EEG Analysis Using Wavelet Transform Features</i> ” (Yavuz & Aydemir, 2016).	Privados	Wavelet Transform	Olores usados fueron queso y flor de loto. Análisis de dominio de frecuencia.
“ <i>Retracted: Analysis of the Influence of Complexity and Entropy of Odorant on Fractal Dynamics and Entropy of EEG Signal</i> ” (Namazi et al., 2016).	Privados	Procesamiento Wavelet	El odorante estructuralmente más complejo causa menos señal de EEG fractal. Además, el olor que tiene una entropía más alta hace que la señal de EEG tenga una entropía aproximada más baja.
“ <i>A triangular hashing learning approach for olfactory EEG signals recognition</i> ”(Hou et al., 2022 ^a).	Datos encontrados en repositorio IEEE	triangular hashing learning	Se ejecuta triangulación entre electrodos mediante comparación e identificando así los electrodos con mayor actividad correspondiente estímulo olfativo.

Tabla 4. Identificación de investigaciones en las que se implementó el uso de señales EEG.

Las investigaciones mencionadas en la tabla 4, realizan procesamiento y análisis de señales EEG en todos los electrodos con la distribución 10-20 sobre el cuero cabelludo, en su mayoría implementan algoritmos en el dominio de la frecuencia, no se produce desarrollo de software.

4.10.2 Identificación de investigaciones en las que se implementó el uso de señales EBG

<i>Artículo</i>	<i>Datos</i>	<i>Método y observaciones</i>
<p><i>“A non-invasive olfactory bulb measure dissociates Parkinson’s patients from healthy controls and discloses disease duration”</i>(Iravani et al., 2021).</p>	<p>Datos de dominio público en repositorio OSF</p>	<p>Para eliminar artefactos no relacionados con la señal, las pruebas con artefactos musculares y de parpadeo se identificaron mediante un algoritmo automático y se eliminaron del análisis posterior. El algoritmo de identificación automática de artefactos incluyó: filtrado, transformada de Hilbert, puntuación z de la señal envolvente y umbralización con un valor z de corte de 8 para los músculos y 4 para los artefactos de parpadeo.</p>
<p><i>“Non-invasive recording from the human olfactory bulb”</i>(Iravani et al., 2020b).</p>	<p>Datos de dominio público en repositorio OSF</p>	<p>Descomposición tiempo-frecuencia del sensor de la diferencia de potencia para el aire frente a la condición inicial para los electrodos EBG. Estadísticas T derivadas de 1000 permutaciones de Monte Carlo.</p>

Tabla 5. Identificación de investigaciones en las que se implementó el uso de señales EBG.

Las fuentes mencionadas de la tabla 5, corresponden a investigaciones de base en el concepto de EBG, realizan distribución de 4 electrodos en la zona frontal de la cabeza, solo existen estas dos fuentes bibliográficas y sus datos correspondiente estas investigaciones se trabajan en el dominio de tiempo. Frecuencia y frecuencia.

4.10.3 La implementación de aprendizaje automático en el campo del procesamiento digital de bioseñales proporciona mayor calidad en los datos(Acharya et al., 2017; Lotte et al., 2018), mejorando la precisión en el diagnóstico y eliminado los posibles sesgos del

personal de la Identificación bibliográfica de algoritmos de aprendizaje automático implementados en el procesamiento de señales

<i>Fuente</i>	<i>Aprendizaje automático en procesamiento de señales</i>
<i>“Biomedical Signal Processing and Artificial Intelligence in Healthcare”</i> (Zgallai, 2020).	Redes neuronales convolucionales profundas usando <i>Keras</i> y <i>TensorFlow</i> , Máquina de Soporte Vectorial, K- vecino cercano, árboles de decisión, redes neuronales, entre otros(Zgallai, 2020) .
<i>“Biomedical Signal Analysis and Its Usage in Healthcare”</i> (Sudip, 2019).	Redes neuronales con función de base radial, K- Vecinos cercanos, redes neuronales, máquina de vectores de soporte, reducción de dimensionalidad, sistema de inferencia neurodifusa adaptativa (ANFIS), entre otros. (Sudip, 2019).
<i>Machine Learning and the Internet of Medical Things in Healthcare</i> (Singh et al., 2021).	Redes neuronales profundas, convolucionales, recurrentes; lógica difusa, optimización del enjambre de partículas (PSO), función de base radial (Singh et al., 2021).

Tabla 6. Identificación bibliográfica de algoritmos de aprendizaje automático implementas en el procesamiento de señales.

En la tabla 6 se identifica el que uno de los algoritmos con mayor concurrencia de uso en el procesamiento de señales corresponde a K- vecinos cercanos.

4.10.4 Identificación bibliográfica de algoritmos de aprendizaje automático implementados al análisis de señales olfatorias

<i>Artículos</i>	<i>Datos</i>	<i>Aprendizajes no supervisados en el análisis de señales EEG</i>
<i>“Decoding olfactory EEG signals for different odor stimuli identification using wavelet-spatial domain feature”</i> (Zhang et al., 2021)	Datos de tipo cuantitativo de dominio privado.	Bayesiano ingenuo, redes neuronales de retropropagación, K-vecinos cercanos y máquina de aprendizaje extremo(Zhang et al., 2021).
<i>“A triangular hashing learning approach for olfactory EEG signal recognition”</i> (Hou et al., 2022b) .	Datos de tipo cuantitativo de acceso restringido en repositorio de IEEE	Triangular <i>hashing learning</i> en comparación con métodos tradicionales como: K- vecinos cercanos, redes neuronales convolucionales, máquina de vector soporte, análisis discriminante lineal, entropía de Shannon, redes neuronales recurrente (Hou et al., 2022b).
<i>“Spatial-frequency-temporal convolutional recurrent network for olfactory-enhanced EEG emotion recognition”</i> n(Xing et al., 2022).	Datos de tipo cuantitativo de dominio privado.	Red recurrente convolucional.(Xing et al., 2022).

Tabla 7. Identificación bibliográfica de algoritmos de aprendizaje automático implementas al análisis de señales olfatorias.

El procesamiento y algoritmos mencionados en la Tabla 7 corresponden a la implementación de las señales EEG, siendo algoritmos mas no un desarrollo de aplicativos que permita la

caracterización de las señales mediante el aprendizaje no supervisado permitiendo el usando diferentes tipos de bases de datos.

5 Metodología

En esta investigación se propone el desarrollo de un modelo de aprendizaje automático no supervisado, para la caracterización de *OERP* provenientes de señales EBG por lo tanto esta investigación se desarrollarla mediante la implementación de la modelo CRISP- DM(*Cross-Industry Standard Process for Data Mining*)(IBM, 2021a), este modelo instruye trabajos e investigación en minería de datos. Reuniendo cuatro etapas fundamentales 1. Entendimiento del problema, 2. Entendimiento de los datos, 3. Preparación de los datos, 4. Modelado, 5. Evaluación y 6. Despliegue, como se puede observar en la (Ilustración 2).

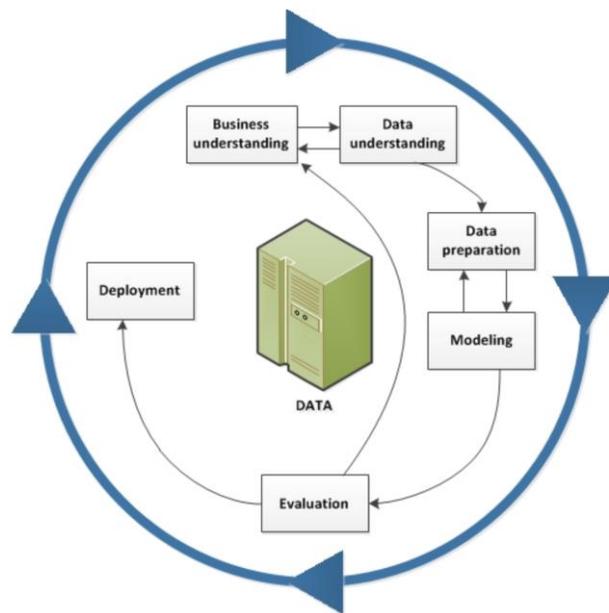


Ilustración 2. Componentes del modelo CRISP-DM, ciclo de vida de minería de datos tomado de IBM (IBM, 2021b).

5.1 Entendimiento del problema

Los biopotenciales se caracterizan por contar con grandes volúmenes de datos, en esta investigación se propone extraer características específicas de las señales EBG mediante el desarrollo e implementación de algoritmos con aprendizaje automático.

- A. Objetivo de esta investigación: Caracterizar el comportamiento de los *OERPs* de las señales EBG de forma cuantitativa mediante la implementación de un modelo de aprendizaje no

supervisado, con el fin de obtener una línea base para el desarrollo de métodos para el apoyo diagnóstico preclínico de enfermedades relacionadas a alteraciones olfativas y/o neurodegenerativas.

- B. Estado de la situación: Tal como se citó en el estado del arte, el aprendizaje automático se ha implementado en el área de la salud, mediante la implementación y caracterización de imágenes médicas, patologías, procesamiento de señales, entre otras. Los modelos de aprendizaje automático no se han implementado en la caracterización de señales EBG para el desarrollo de software, debido a que este término es relativamente nuevo. La bibliografía que hace referencia a este tipo de señales se ha enfocado en demostrar la existencia y la eficiencia de la técnica de ubicación de los electrodos en la que se realiza la colección de datos y de la actividad eléctrica del bulbo olfatorio.
- C. Objetivo de predicción: Caracterizar los ERP olfativos por medio de algoritmo de aprendizaje automático no supervisado, que permita identificar el comportamiento en las señales EBG de forma cuantitativa en personas saludables a partir de conjuntos de datos del dominio público.
- D. Plan de proyecto: Este proyecto se desarrollarla según las actividades y tiempos planteados en el cronograma adjunto al final de este documento.

5.2 Entendimiento de los datos

Para el desarrollo de esta investigación, mediante el uso de datos públicos hallados en el repositorio “*Open Science Framework*” (OSF), siendo datos de tipo cuantitativos.

- A. Naturaleza de los datos:
 - Datos cuantitativos.
 - Su almacenamiento se da en matrices, por lo tanto, cada elemento de esta matriz representa la diferencia de potencial medido, el tamaño de la matriz esta dado por el numero usado, el tiempo y la frecuencia de adquisición.
 - En la pesquisa de las bases de datos que cumplan con las necesidades de esta investigación, se identificó la base de datos denominada “Diagnostico diferencial de

síndromes demenciales para el reconocimiento de Alzheimer en personas con déficit cognitivo leve: potenciales biomarcadores de señales EEG” (Sarmiento, 2024) que corresponde a señales EEG durante el proceso de olfacción.

B. Descripción de los datos

Repositorio	Acceso	Tipo de dato	Proyecto	Comité de ética	Características de los sujetos	Olores
OSF	Público/ media solicitud https://osf.io/ed6kh/	Cuantitativo	Diagnostico diferencial de síndromes demenciales para el reconocimiento de Alzheimer en personas con déficit cognitivo leve: potenciales biomarcadores de señales EEG.	Comité de ética CEP-CONEP de la Universidad Estadual de Santa Cruz UESC mediante parecer 1.748.562 el 28 de septiembre del 2016, Con registro en plataforma Brasil código CAAE: 50412215.8.000 0.5526.	Los voluntarios de la investigación son 10 estudiantes latinoamericanos (6 hombres, 4 mujeres) de pós-graduación de la Universidad Estadual de Santa Cruz UESC con edades entre 23 y 33. No presentan alteraciones cognitivas, olfativas, o uso de medicamentos que alteren el funcionamiento cognitivo.	Naranja Cuero Canela Menta Banana Limón Regaliz-Anís Trementina Ajo Café Manzana Clavo Piña Rosa Anís Pez

Tabla 8. Descripción de la base de datos “Diagnostico diferencial de síndromes demenciales para el reconocimiento de Alzheimer en personas con déficit cognitivo leve: potenciales biomarcadores de señales EEG”

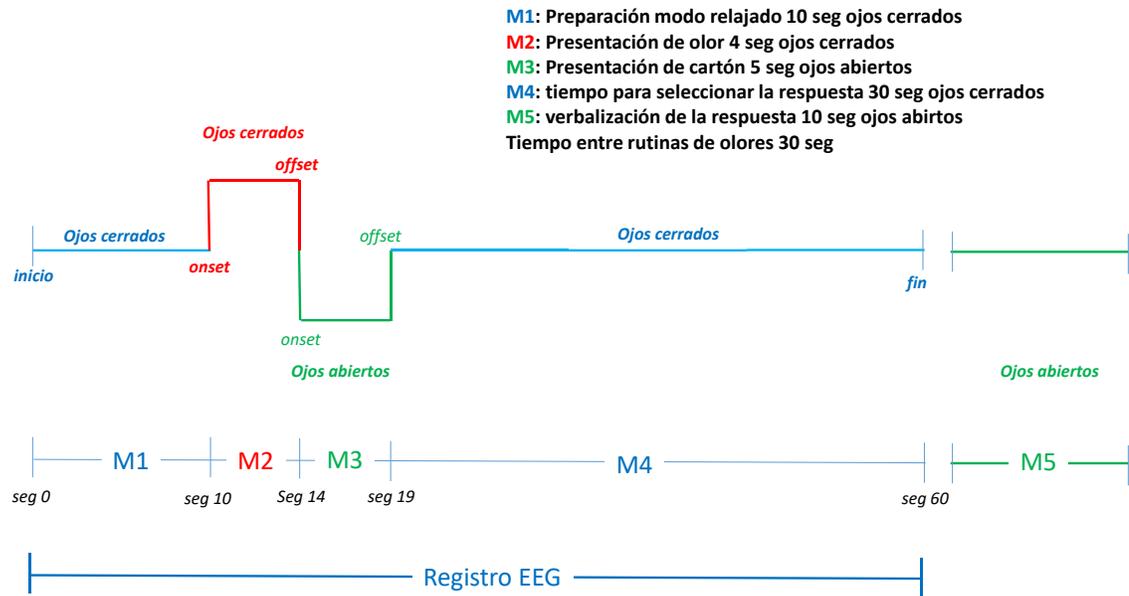


Ilustración 3. Protocolo de adquisición de los datos (Sarmiento, 2024), para esta investigación se tiene en cuenta el segmento M2 y M3.

La ilustración 3, indica el protocolo de adquisición de las señales de la base de datos seleccionada, en el que M1: corresponde a la preparación modo relajado durante 10 segundos con los ojos cerrados, M2: Preparación de olor 4 segundos con los ojos cerrados, M3: Presentación del cartón con las opciones de los olores, M4: Tiempo para seleccionar la respuesta de 30 segundos con los ojos cerrados y M5: Corresponde a la verbalización de la respuesta con los ojos abiertos. Para esta investigación se implementará los segmentos M2 y M3.

5.3 Preparación de los datos

Para el desarrollo de esta investigación es importante la preparación de los datos como fase inicial del proceso el cual conlleva a varios procesos

5.3.1 Selección de olores a implementar

Esta selección se llevó a cabo mediante revisión bibliográfica, la cual permitió identificar los olores más comunes usados en otras investigaciones que están relacionadas con la olfacción y su respuesta electroencefalográfica:

Investigación	Olores implementados
<i>Brain and odor: 1. Alteration of human EEG by odor administration</i> (Lorig & Schw Artz, 1988).	Manzana, eucalipto, lavanda, agua control.
<i>Topographical EEG maps of human responses to odors</i> (Klemm et al., 1992).	Lavanda, alquitrán de abedul, galvano, heliotropina, jazmín, limón, meta. Frecuencia Theta con mayor representatividad.
<i>Functional MR Imaging of Regional Brain Responses to Pleasant and Unpleasant Odors</i> (Bowers et al., 1998).	Trementina, ácido isovalérico, aire.
<i>Human electroencephalographic (EEG) response to olfactory stimulation: Two experiments using the aroma of food</i> (Martin, 1998b).	Chocolate, menta verde, almendra, fresa, vegetal, ajo, cebolla, comino. Asociando una reducción significativa en la onda Theta.
<i>On the similarity of odor and language perception</i> (Tyler S. Lorig, 1999).	Limón y ácido propiónico.
<i>Electroencephalographic Response to Different Odors in Healthy Individuals: A Promising Tool for Objective Assessment of Olfactory Disorders</i> (Krbot Skorić et al., 2015b).	Menta, Limón, Vainilla.
<i>Relationship between Mood Change, Odor and Its Psychophysiological Responses in Humans in Terms of the Sensory Evaluation Spectrum</i> (Sugawara et al., 2015).	Limón, menta, canela, naranja.
<i>Influence of Fragrances on Human Psychophysiological Activity: With Special Reference to Human Electroencephalographic Response</i> (Sowndhararajan & Kim, 2016).	Limón, menta.

Tabla 9. Revisión bibliográfica de olores usados investigaciones relacionadas con procesamiento de señales.

Teniendo en cuenta la tabla 9, se puede referenciar mediante bibliografía los olores que se han usado concurrentemente en investigaciones en las que se analiza la relación EEG olfato, para el desenvolvimiento de esta investigación se trabaja en la onda Theta (4 - 7 Hz) proporcionado por las señales correspondientes a siete olores (limón, menta, ajo, trementina, manzana, naranja, canela) que se encuentran en la base de datos seleccionada “Diagnostico diferencial de síndromes demenciales para el reconocimiento de Alzheimer en personas con déficit cognitivo leve: potenciales biomarcadores de señales EEG”, cuenta con 24 canales con los cuales se adquirieron las señales con la configuración estandarizada de electros 10-20 sobre el cuero cabelludo como se observa en la Ilustración 4, Cuyos electros de importancia para esta investigación son Fp1, Fp2 y Fpz, debido a que estos se encuentran ubicados en la zona frontal de la cabaza (en la frente), permitiendo obtener el reflejo de la señal proveniente del bulbo olfatorio.

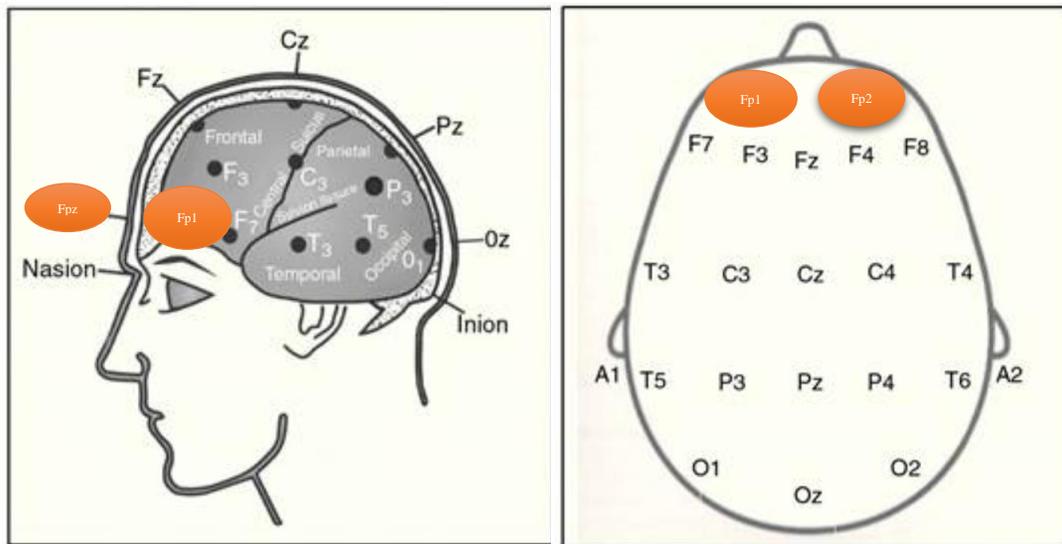


Ilustración 4. Distribución de electrodos estandarizada 10-20 en el cuero cabelludo, imagen tomada de (Carrobles, 2016), se resaltan los canales Fp1, Fp2 y Fpz implementados en la presente investigación.

5.3.2 Limpieza de los datos

En el mundo del procesamiento de bioseñales es importante realizar la normalización de los datos, ya que esto permite ajustar los valores a una escala determinada permitiendo corregir magnitudes, características, ruidos, disparidades y redundancias. Por lo tanto, se ejecutan los siguientes pasos:

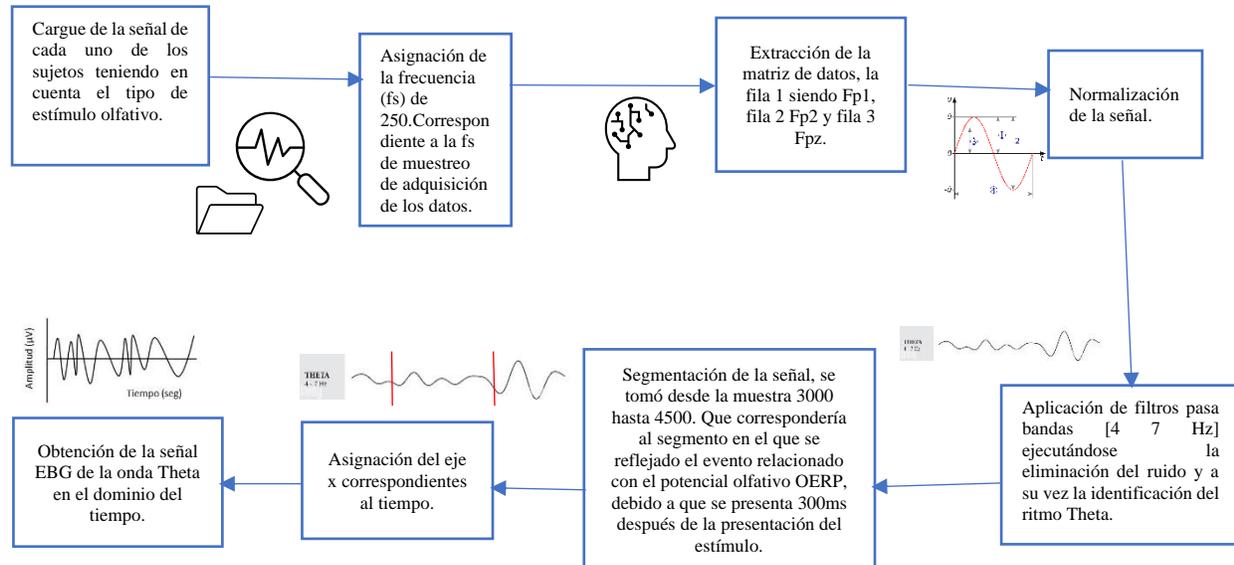


Ilustración 5. Diagrama de flujo correspondiente al procesamiento para la limpieza de los datos de señales EBG para la extrusión del OERP de la onda Theta en el dominio del tiempo desarrollado en este proceso de investigación.

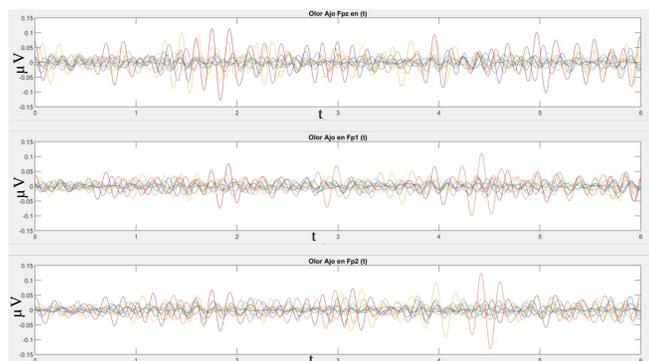


Ilustración 6. Señales EEG onda Theta en el dominio del tiempo (x) – voltaje (y) correspondientes al OERP, aplicando técnicas de preparamiento para segmentación, eliminación del ruido e identificación de la onda Theta.

Para un mayor detalle del proceso de transformación de la señal remitirse al Anexo 1. Código fuente para el procesamiento, segmentación, y extracción de características en el dominio del tiempo y la frecuencia.

5.3.3 Integración y transformación de los datos

La extracción de características de las señales permite transformar en información los datos que fueron sometidos a tratamiento, existe múltiples de procesamiento sin embargo esta investigación permite explorar y observar los *OERP* provenientes de las Señales EBG en el dominio de tiempo.

Una vez se realiza la aplicación de filtros se obtiene la señal en el dominio del tiempo, seguidamente se aplica la transformada rápida de Fourier *FFT* y se extrae en la densidad espectral *PSD*, siendo estos la información que se procesa para la clasificación por agrupación. Anexo 1. Código fuente para el procesamiento, segmentación, y extracción de características en el dominio del tiempo y la frecuencia.

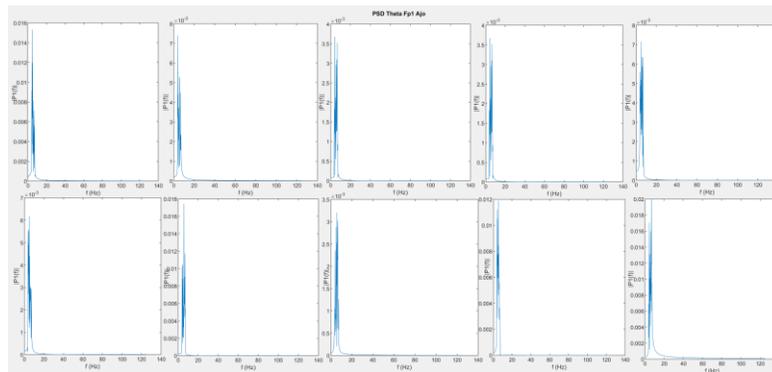


Ilustración 7. Extracción de la densidad espectral *PSD*, correspondiente a la onda Theta de señales EEG durante el OERP.

5.4 Modelamiento

Se desarrolla y se implementa un algoritmo de aprendizaje automático no supervisado, los algoritmos más comunes en este grupo son los de agrupamiento debido a sus similitudes o características semejantes en el conjunto de datos analizados, el modelo a implementar se elegirá a partir de las siguientes opciones:

- A. Modelos de agrupación/clustering: *K-Means*, agrupamiento jerárquico, clústeres basados en la densidad de los puntos, *Mean Shift*, agrupamiento espectral, mezcla de distribuciones gaussianas.

En este caso se realiza mediante el modelo de agrupación *K-Means*, debido a la facilidad de implementación y comprensión, eficiencia computacional, versatilidad, resultados interpretables, robustez y escalabilidad, permitiendo obtener un algoritmo computacionalmente estable que puede manejar grandes volúmenes de datos en poco tiempo de ejecución, los datos usados en esta investigación se distribuirán de la siguiente manera:

- El 70% del total de la base de datos seleccionada será destinada para el entrenamiento del algoritmo.

- El 30% restante de los datos pertenecientes a la base de datos seleccionada serán usados para el proceso de prueba del algoritmo.

5.5 Evaluación

La validación de los resultados obtenidos se da mediante la implementación de análisis estadísticos, ejecución de métricas a partir de medidas de calidad interna de los *Clusters*, esta métrica se observa en la interfaz gráfica del aplicativo permitiendo observar progresivamente durante la clasificación del método *K-means*. La compacidad refleja la cohesión medida de los puntos de un mismo *clúster*, la medida de la compacidad alta indica que la cercanía de los puntos es alta definiendo un clúster compacto y definido. Mientras la separabilidad refleja la medida de la separación entre los *clusters*, una alta separabilidad indica que los *clusters* están bien definidos y se encuentran separado entres si, de esta forma se puede observar y analizar el sistema de clasificación de los OERPs en el dominio del tiempo y/o del PSD.

5.6 Despliegue

El aplicativo desarrollado permite la clasificación mediante el algoritmo por agrupación *K-means* para los canales de Fp1, Fp2 y Fpz, tanto de la OERP de la señal en el dominio del tiempo del ritmo Theta, asi mismo como el *OERP* correspondiente de *PSD* de la señal del ritmo Theta. Esto se relaciona para los olores de Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.

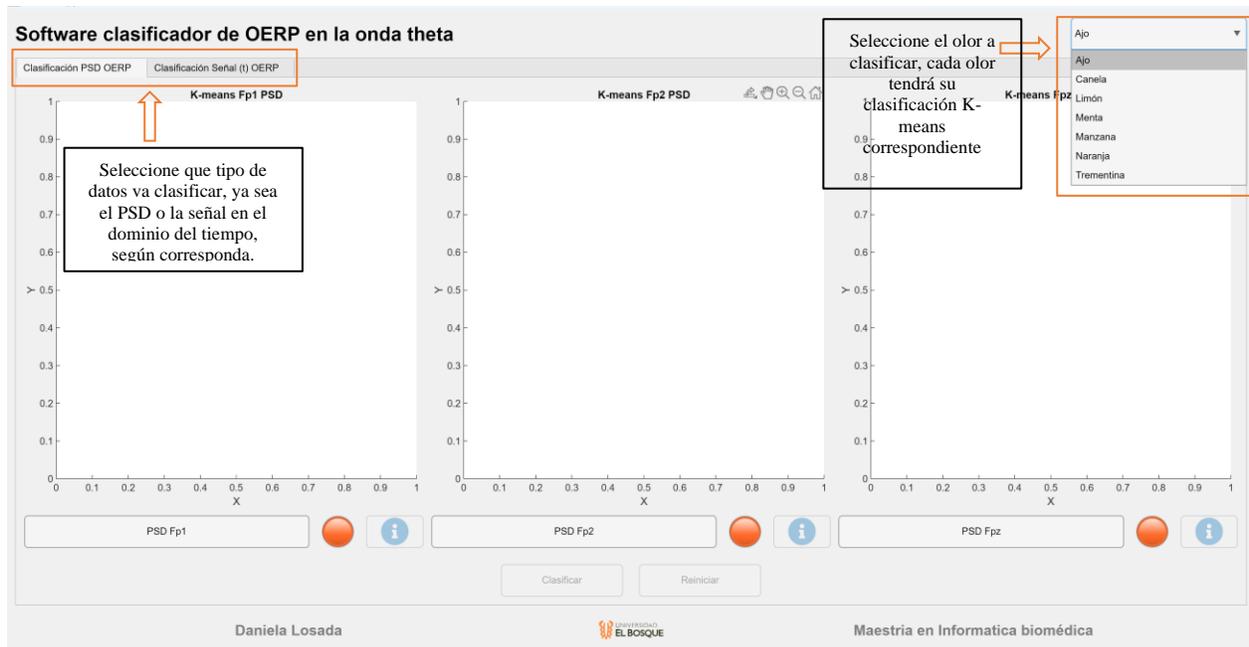


Ilustración 8. Software clasificador de OERP en la onda Theta. Indicaciones del proceso inicial, elección de estímulo olfativo y dominio en el que desea realizar la clasificación.

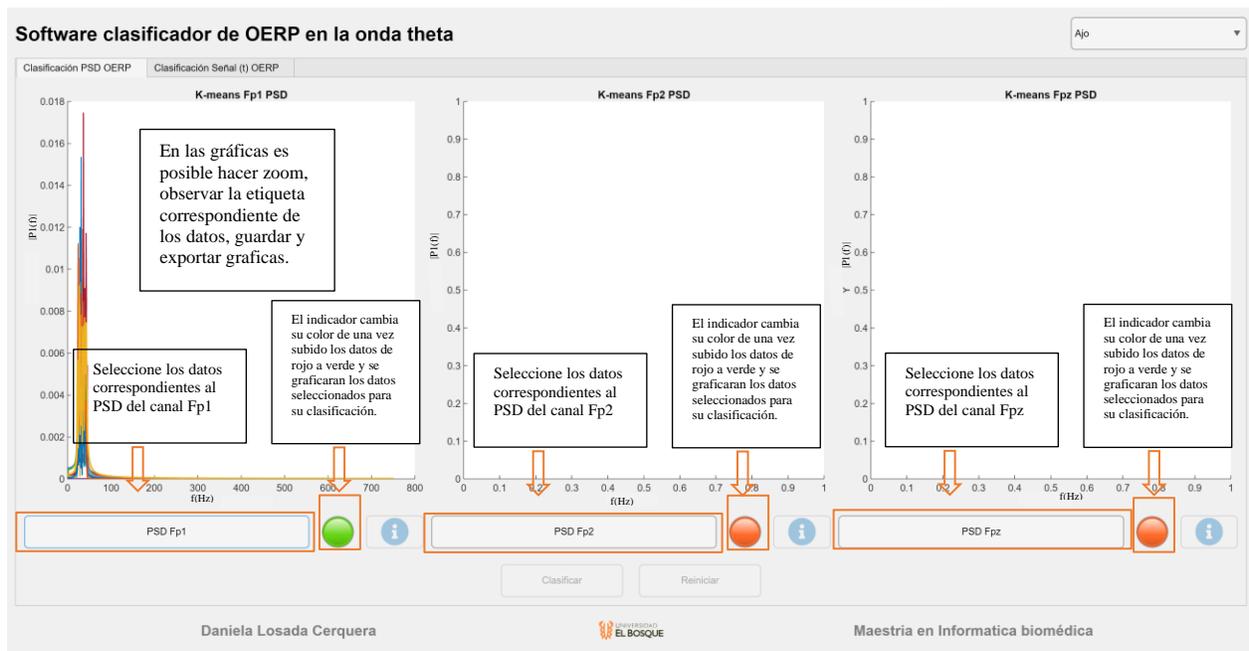


Ilustración 9. Software clasificador de OERP en la onda Theta. Indicaciones del proceso para el cargue del conjunto de datos a analizar e indicadores de cargue exitoso.

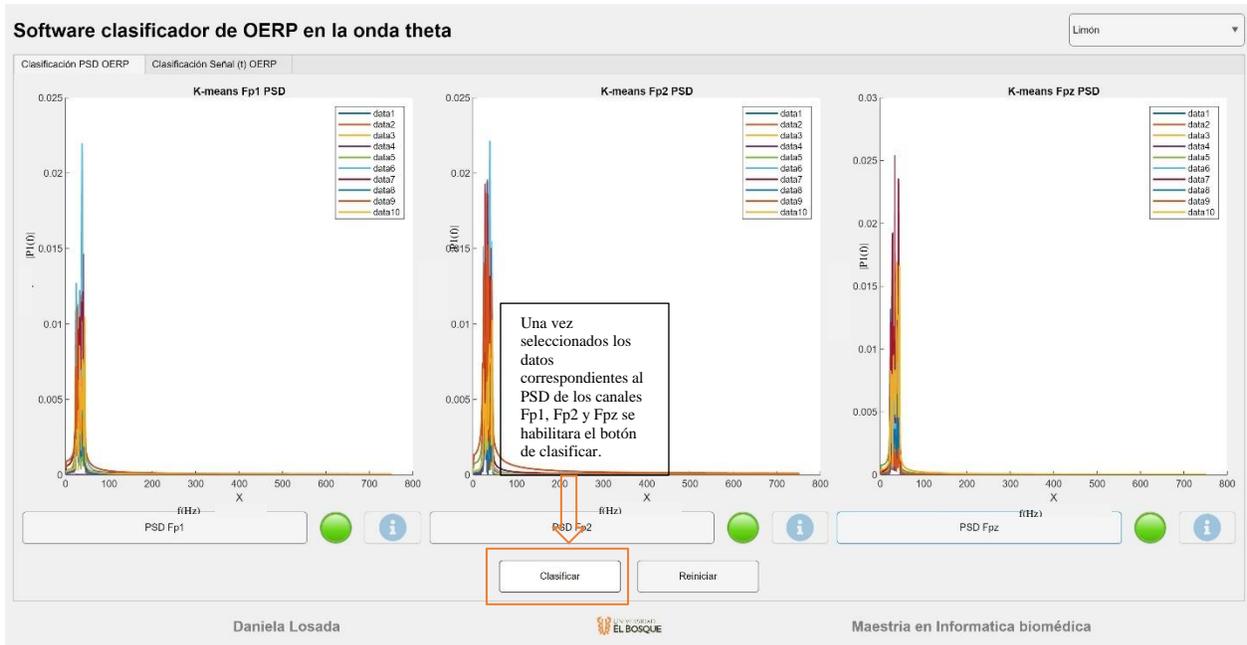


Ilustración 10. Software clasificador de OERP en la onda Theta. Indicaciones iniciar el proceso de clasificación por K.means.

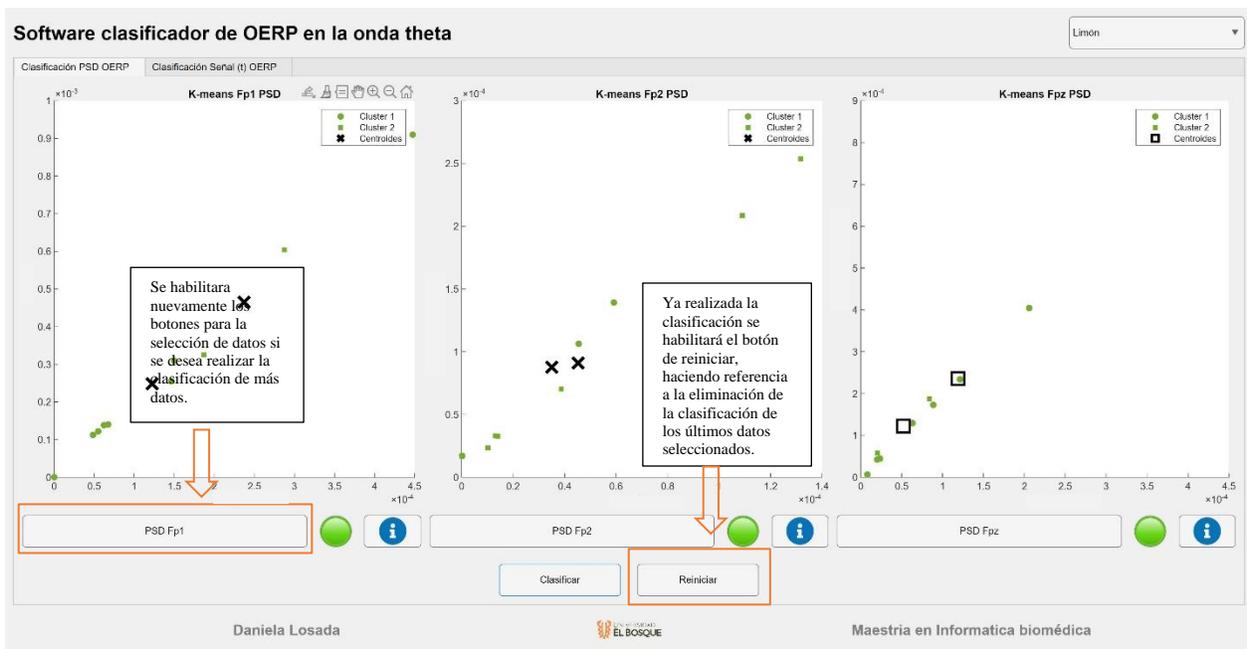


Ilustración 11. Software clasificador de OERP en la onda Theta. Indicaciones restaurar el K.means en caso que se requiera y la habilitación de la sección de cargue de datos para realizar nuevas clasificaciones.

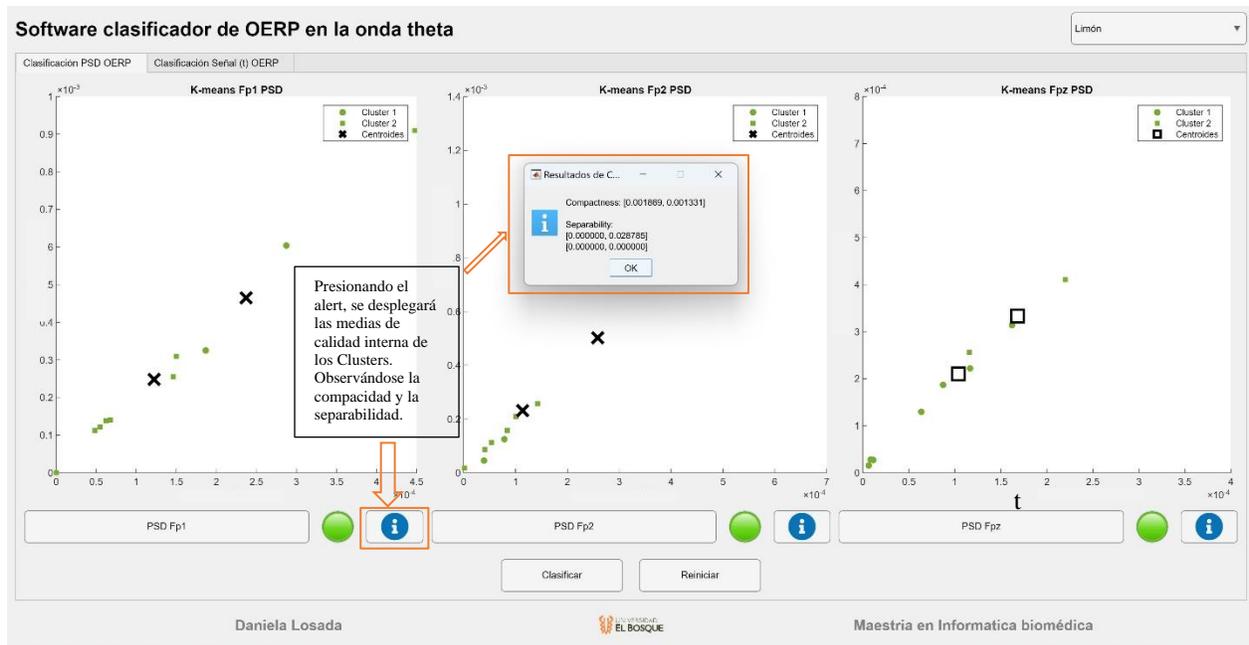


Ilustración 12. Software clasificador de OERP en la onda Theta. Indicador de las medias de calidad interna de los Clusters, la compactidad y la separabilidad respectivamente.

La sección “Clasificador señal(t) OERP”, cumple con las mismas características de funcionalidad descritas con anterioridad a excepción de la gráfica de previsualización de la señal en el dominio del tiempo, la cual tendrá una apariencia sinusoidal como se observa a continuación:

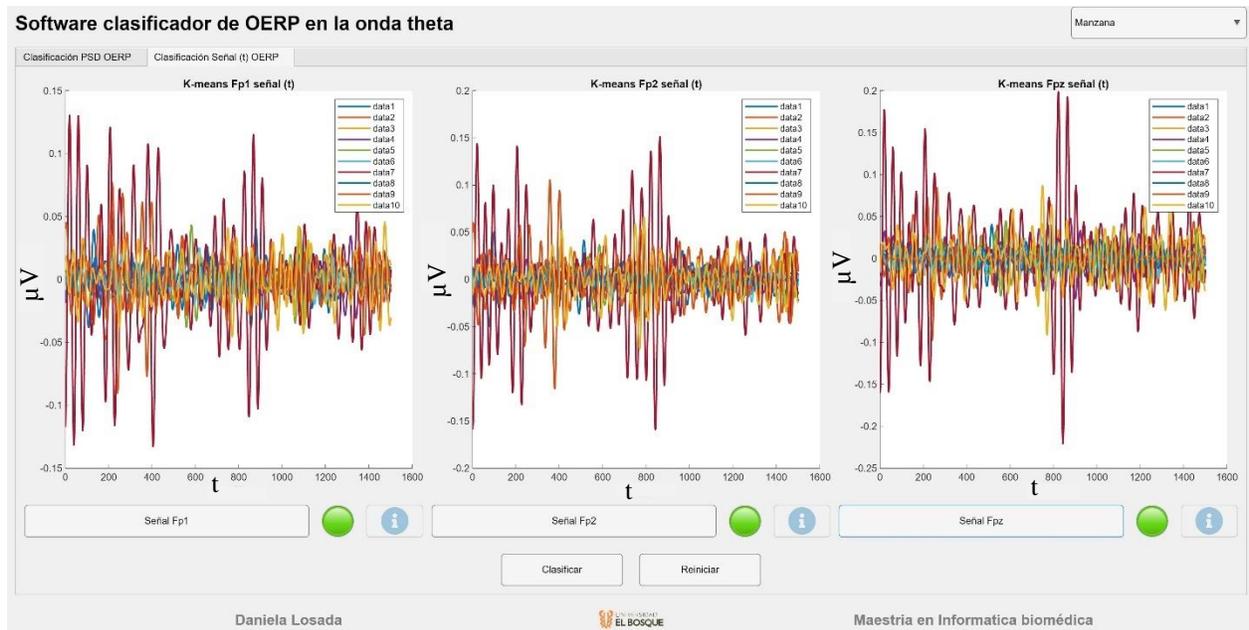


Ilustración 13. Software clasificador de OERP en la onda Theta, En la sección “Clasificador señal(t) OERP” se observará la gráfica de previsualización de la señal en el dominio del tiempo.

5.7 Resultados

El sometimiento de este proyecto de investigación con Código del Proyecto: CIE 2023-115 "Caracterización de los Potenciales Evocados Relacionados con Eventos Olfativos (OERP) provenientes del bulbo olfatorio en personas saludables empleando aprendizaje automático no supervisado" al Comité Institucional de Ética en Investigación de la Universidad El Bosque, fue aprobado en sesión ordinaria del 7 de noviembre de 2023, según Acta No. 024-2023. En la cual se declara Investigación sin Riesgo.

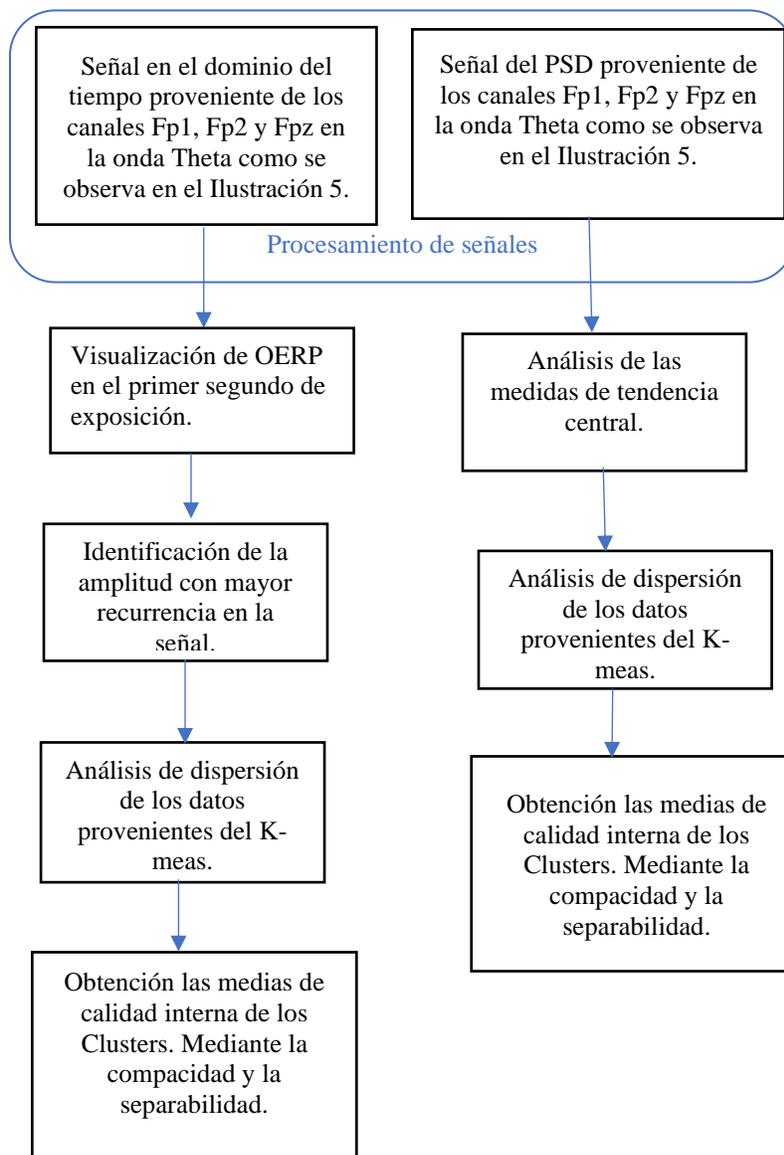


Ilustración 14. Proceso de caracterización de señales.

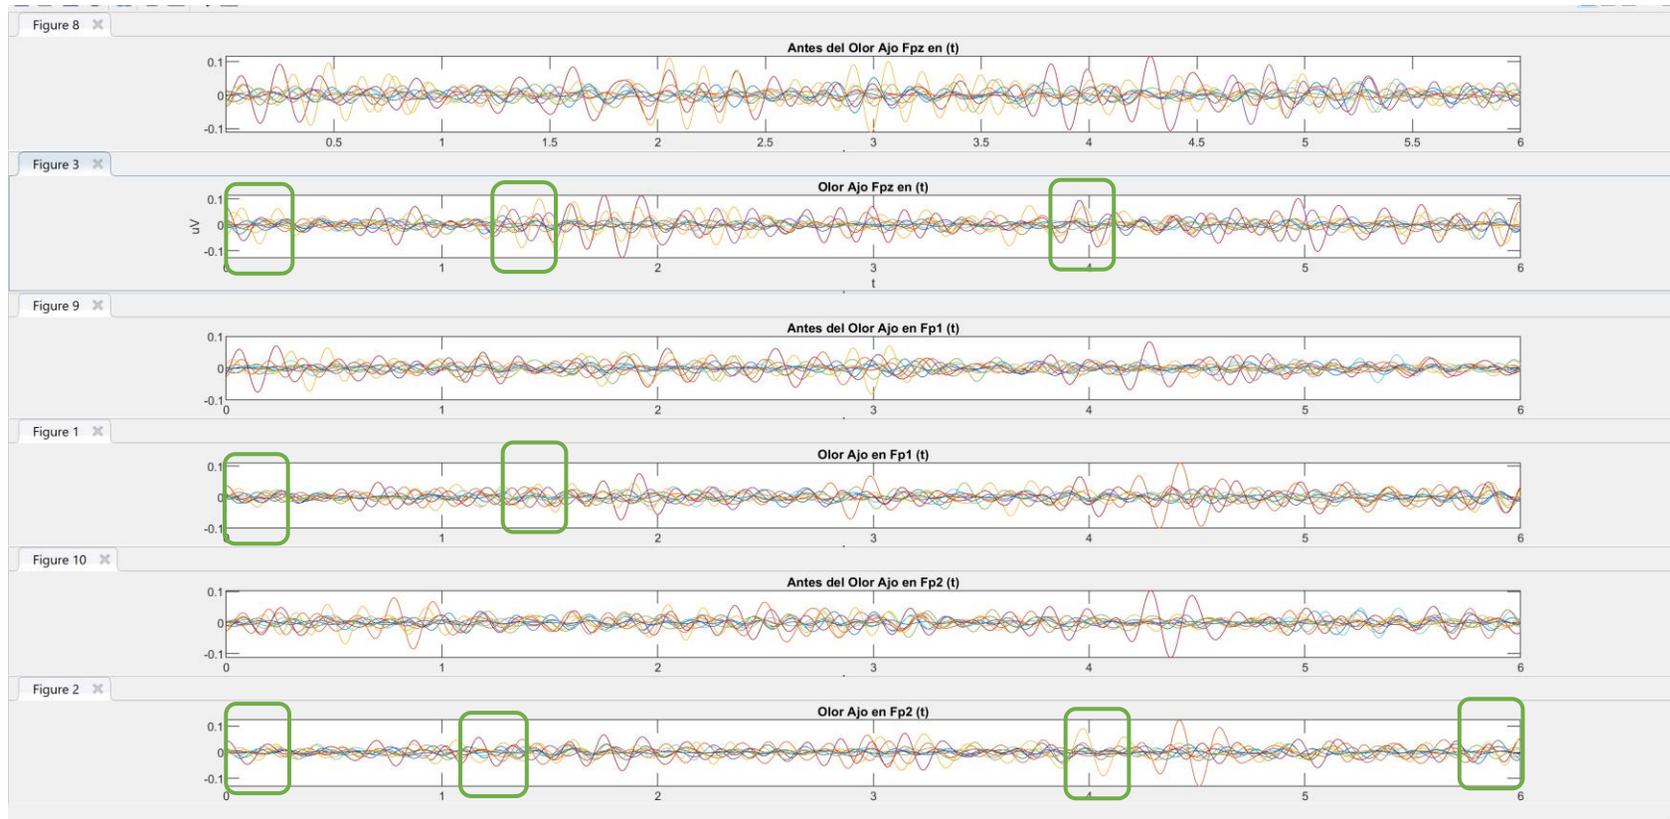


Ilustración 15. Señal en el dominio del tiempo proveniente de los canales Fp1, Fp2 y Fpz en la onda Theta antes de la presentación del estímulo olfativo y durante el OERP como.

En la Ilustración 15, se observan variaciones, pero son difíciles de identificar. Por tanto, el siguiente paso es graficar y analizar la señal correspondiente al primer segundo de la señal, para estimar variaciones que puedan estar relacionadas con el potencial evocado.

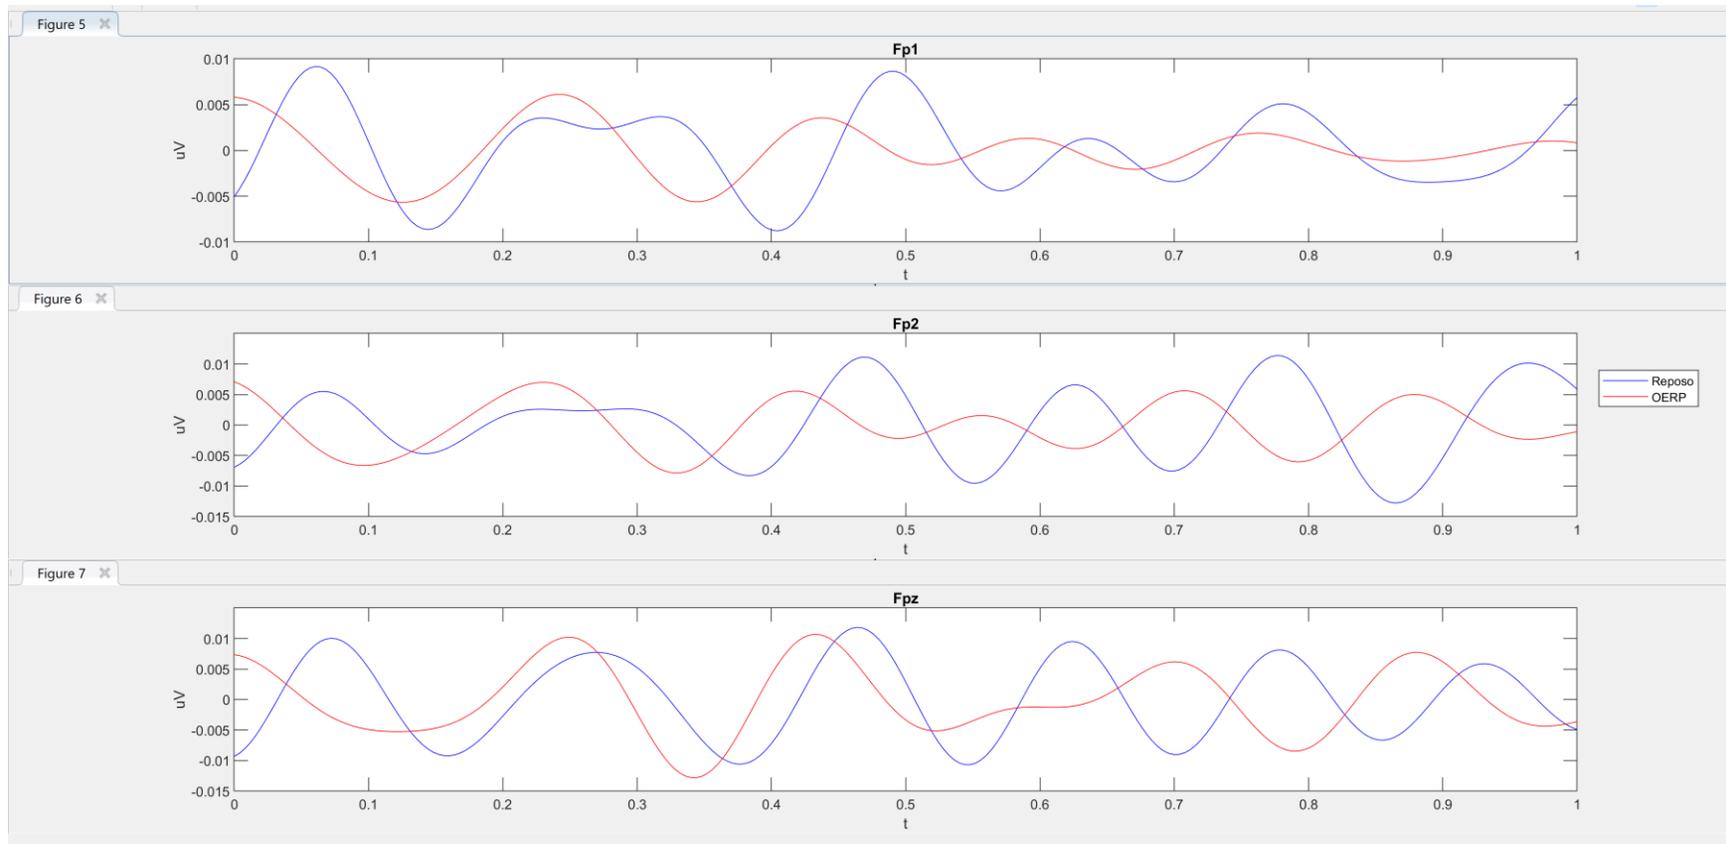


Ilustración 16. Grafica correspondiente a la media de las señales provenientes de los 10 sujetos en olor a Ajo de onda Theta a los canales Fp1, Fp2 y Fpz durante 1 segundo, representándose la señal en reposo en color azul y la señal del OERP en color rojo.

La ilustración 16 en los canales Fp1, Fp2 y Fpz para la señal correspondiente del OERP, se observa una disminución en la amplitud en μV a partir de los 0,5 segundos analizados, en comparación con el comportamiento de la señal en reposo.

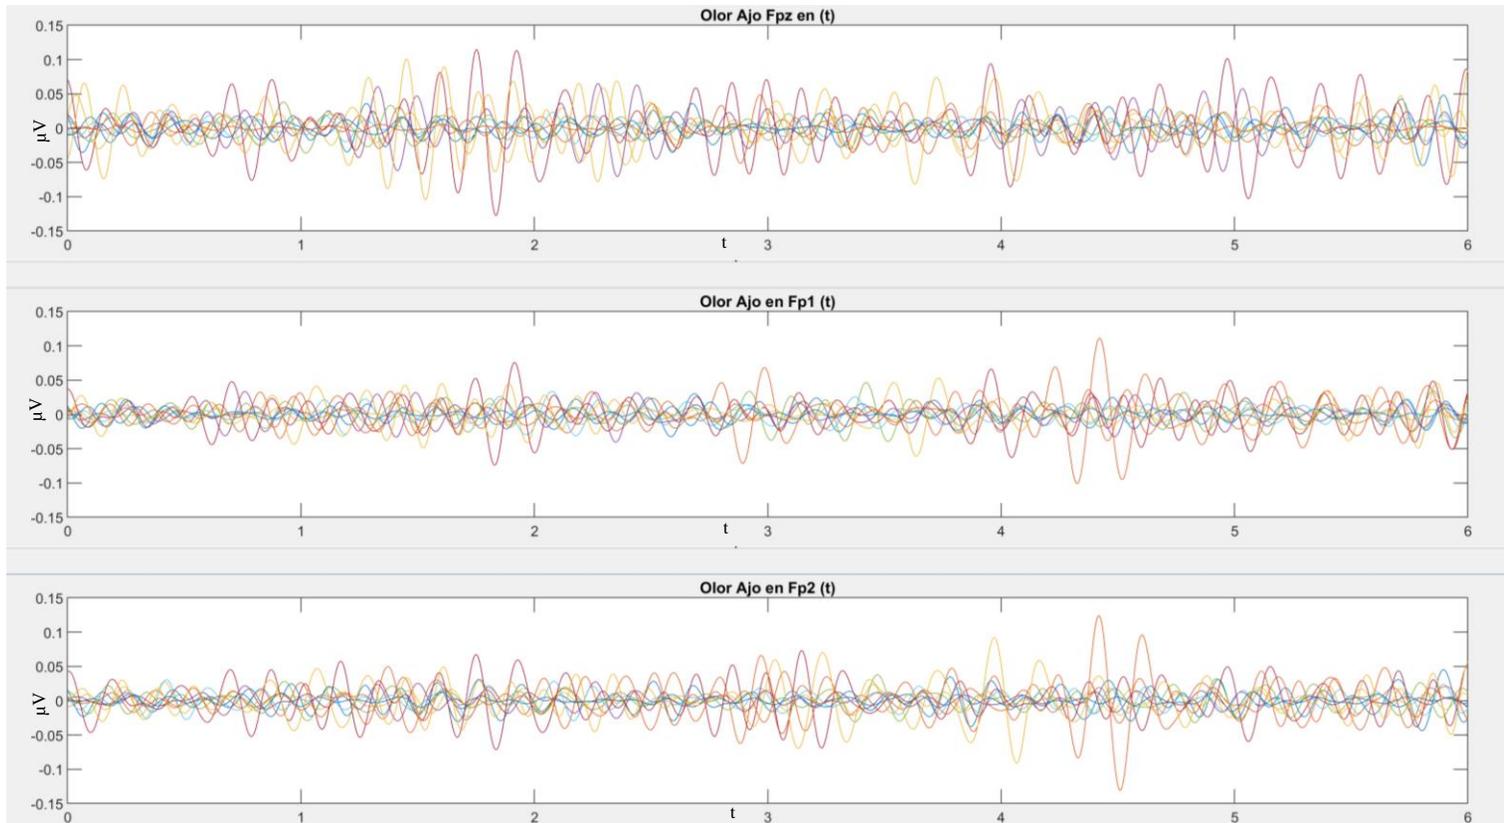


Ilustración 17. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a ajo para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.

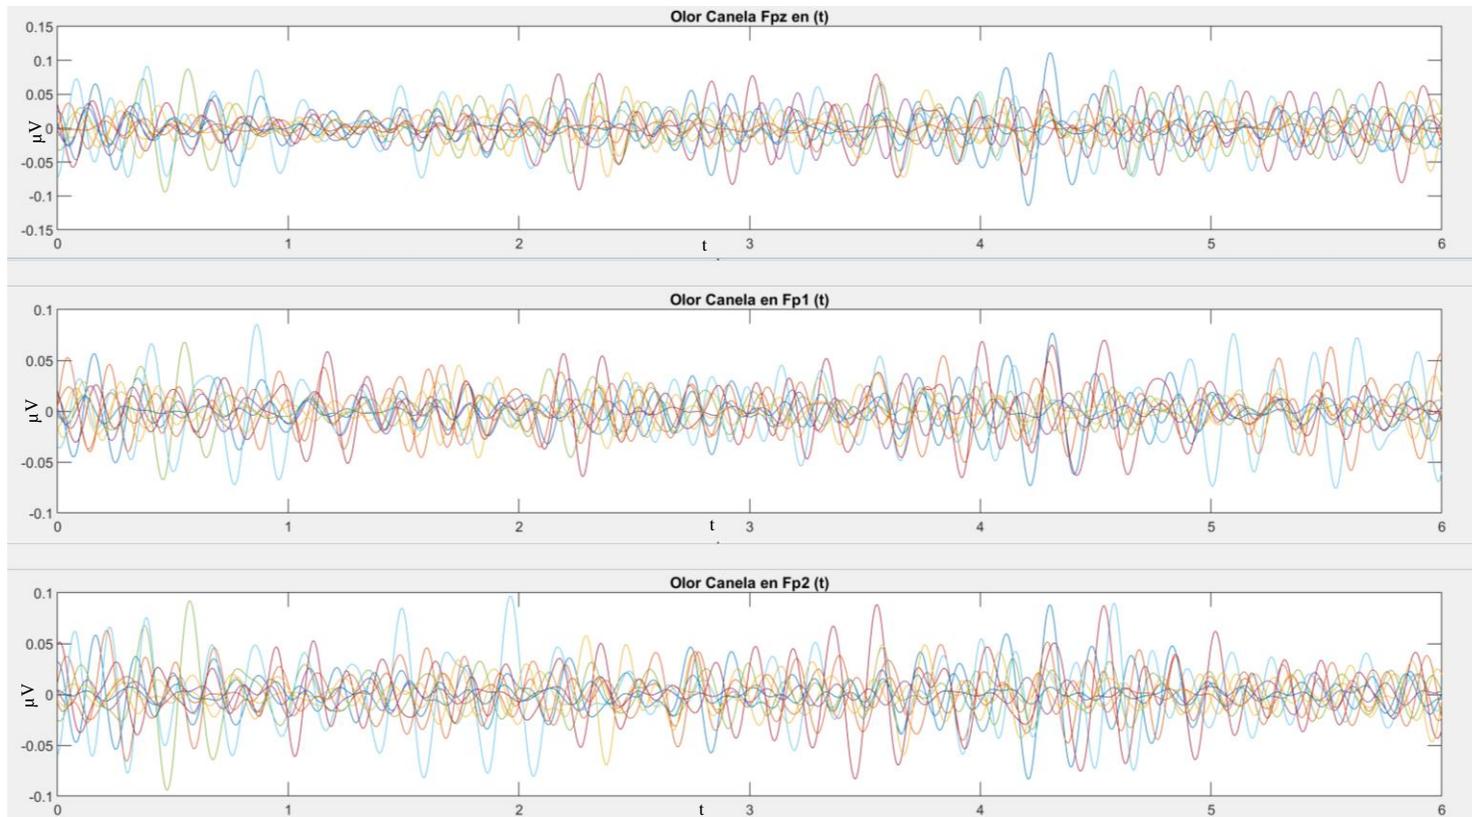


Ilustración 18. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a canela para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud, observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.

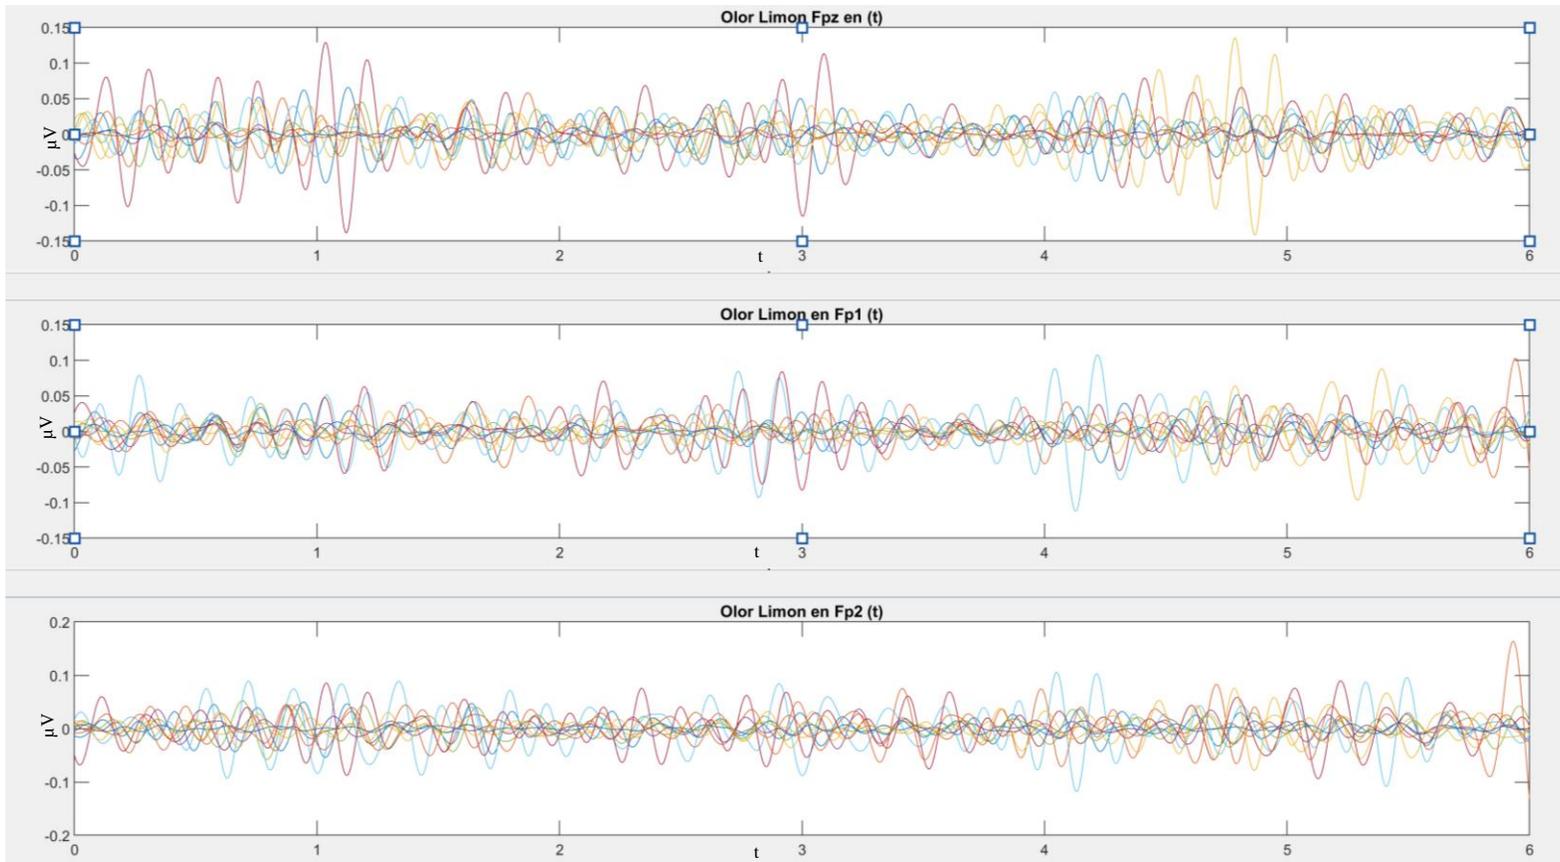


Ilustración 19. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a limón para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.

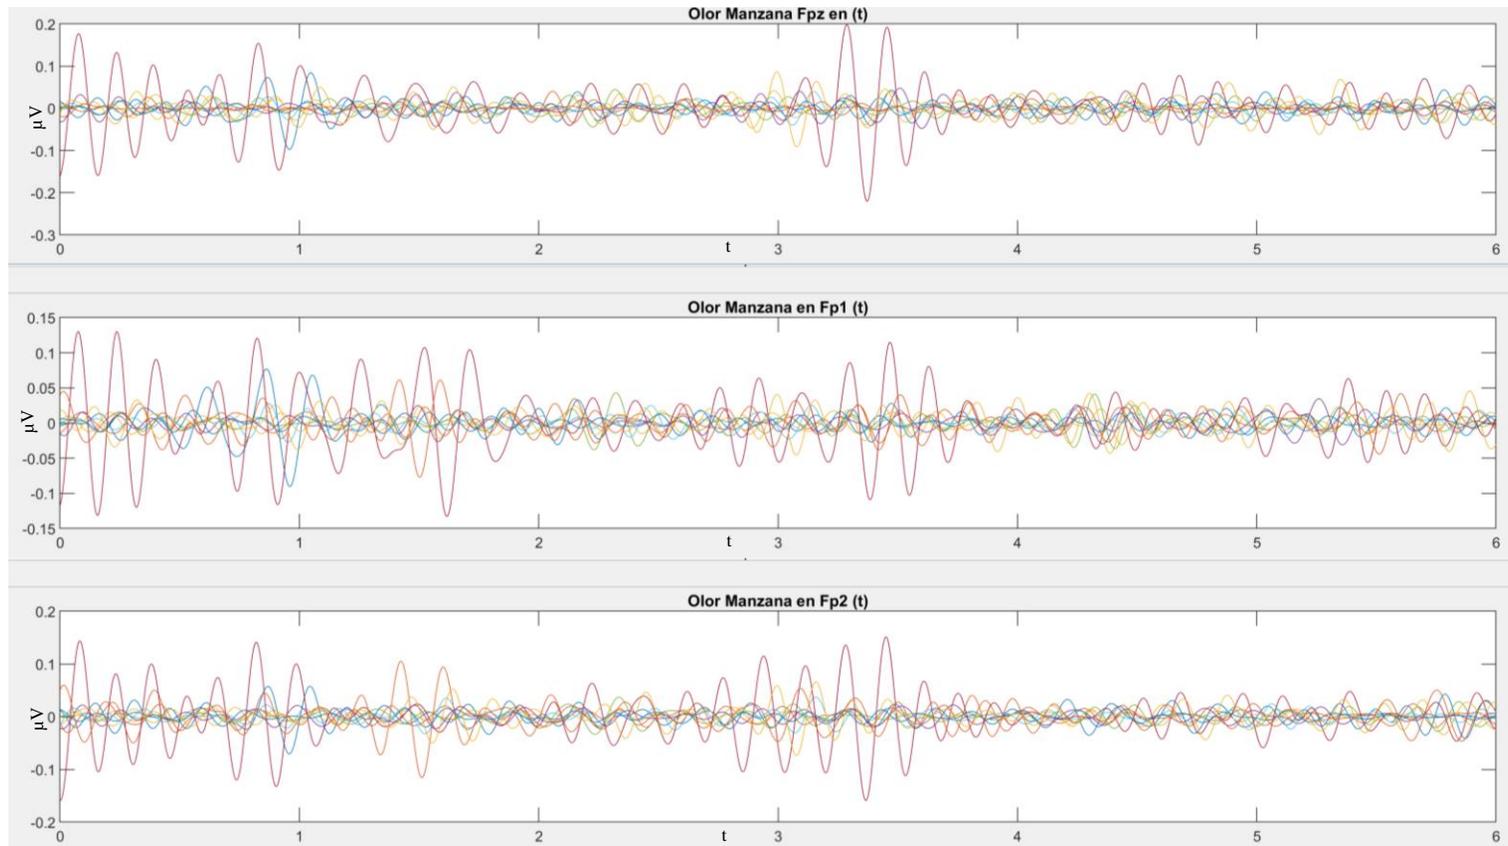


Ilustración 20. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a manzana para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.

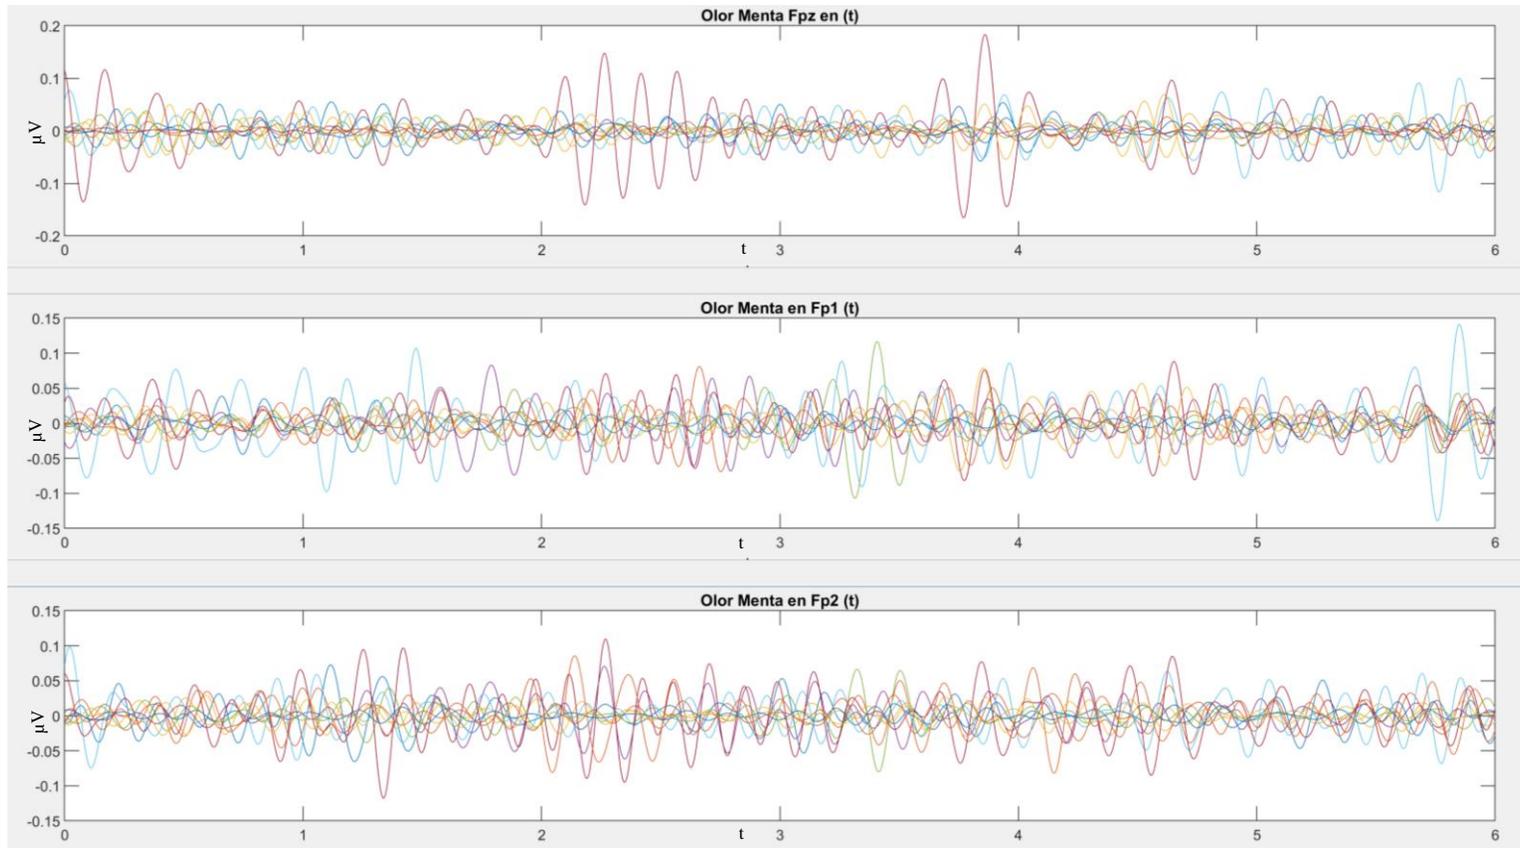


Ilustración 21. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a menta para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.

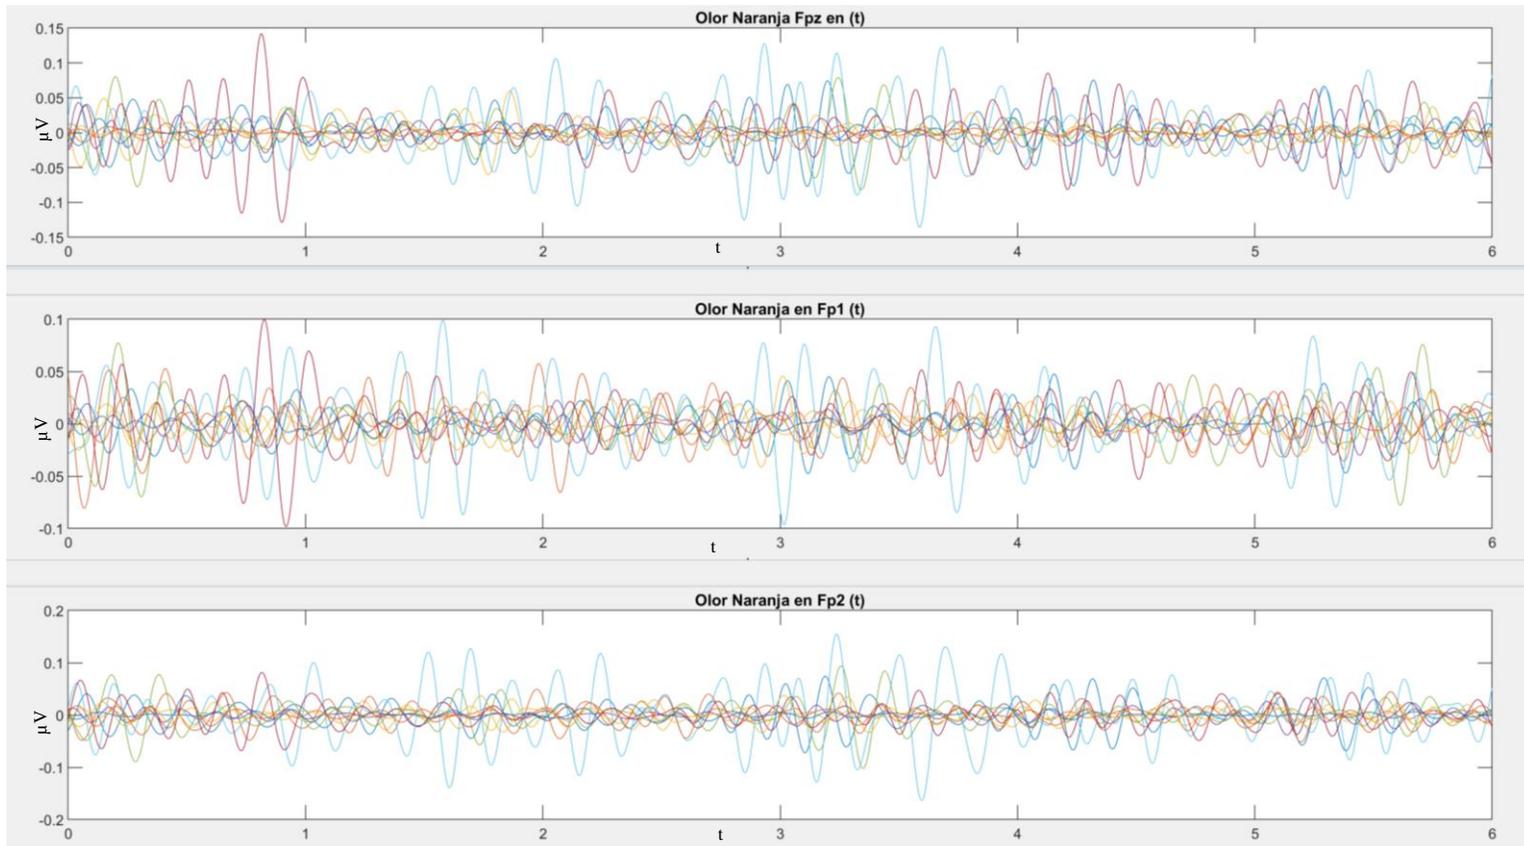


Ilustración 22. Señal resultante del preprocesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a naranja para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.

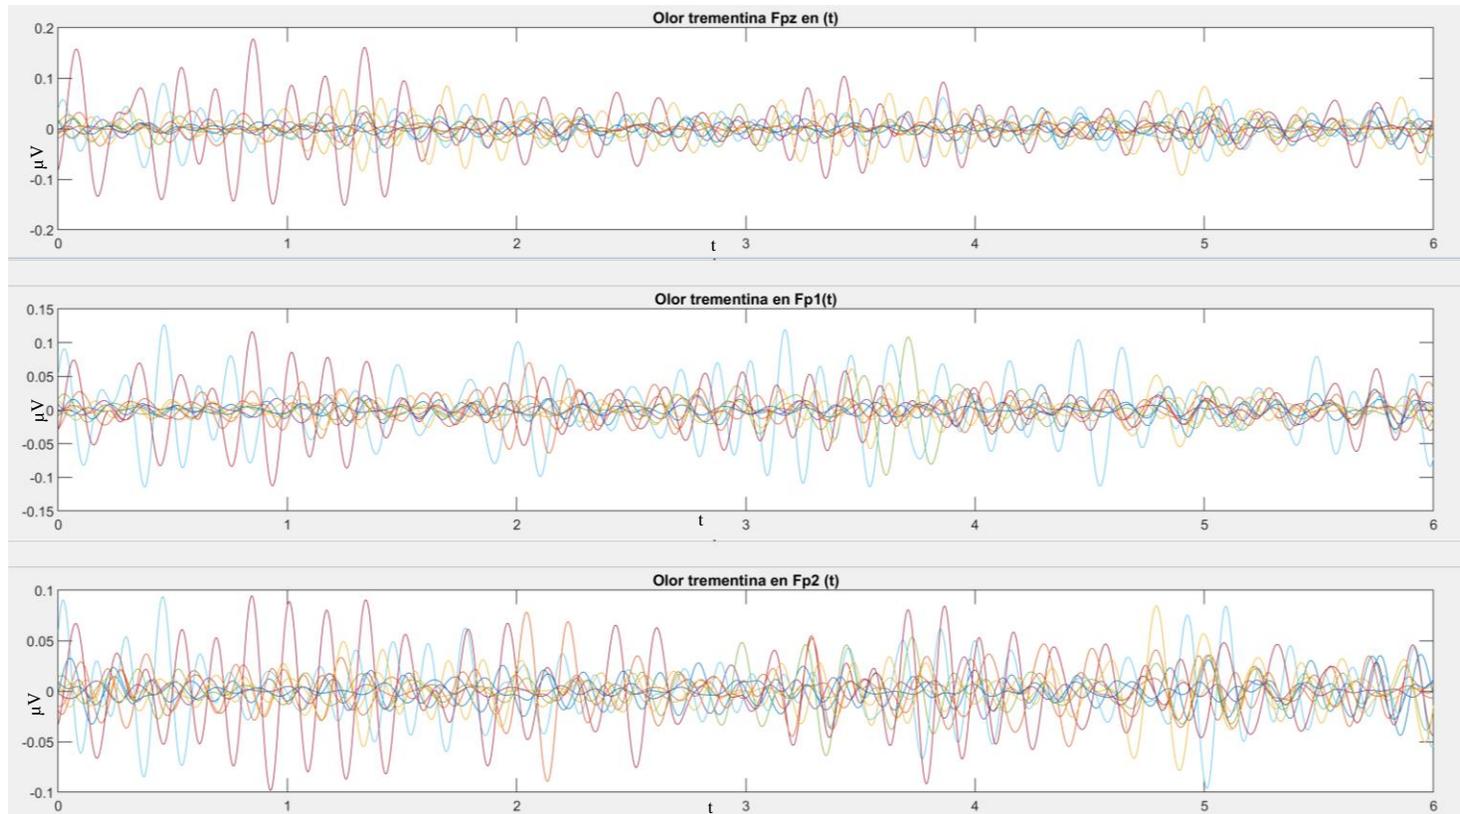


Ilustración 23. Señal resultante del procesamiento de las señales correspondiente a 10 sujetos durante el OERP en el ritmo Theta de olfacción a Trementina para los electrodos Fp1, Fp2 y Fpz, en el eje x denomina el tiempo y en el eje y la amplitud en μV , observándose predominancia en Fpz $[-0,05 \ 0,05] \mu V$, Fp1 $[-0,05 \ 0,05] \mu V$ y Fp2 $[-0,05 \ 0,05] \mu V$.

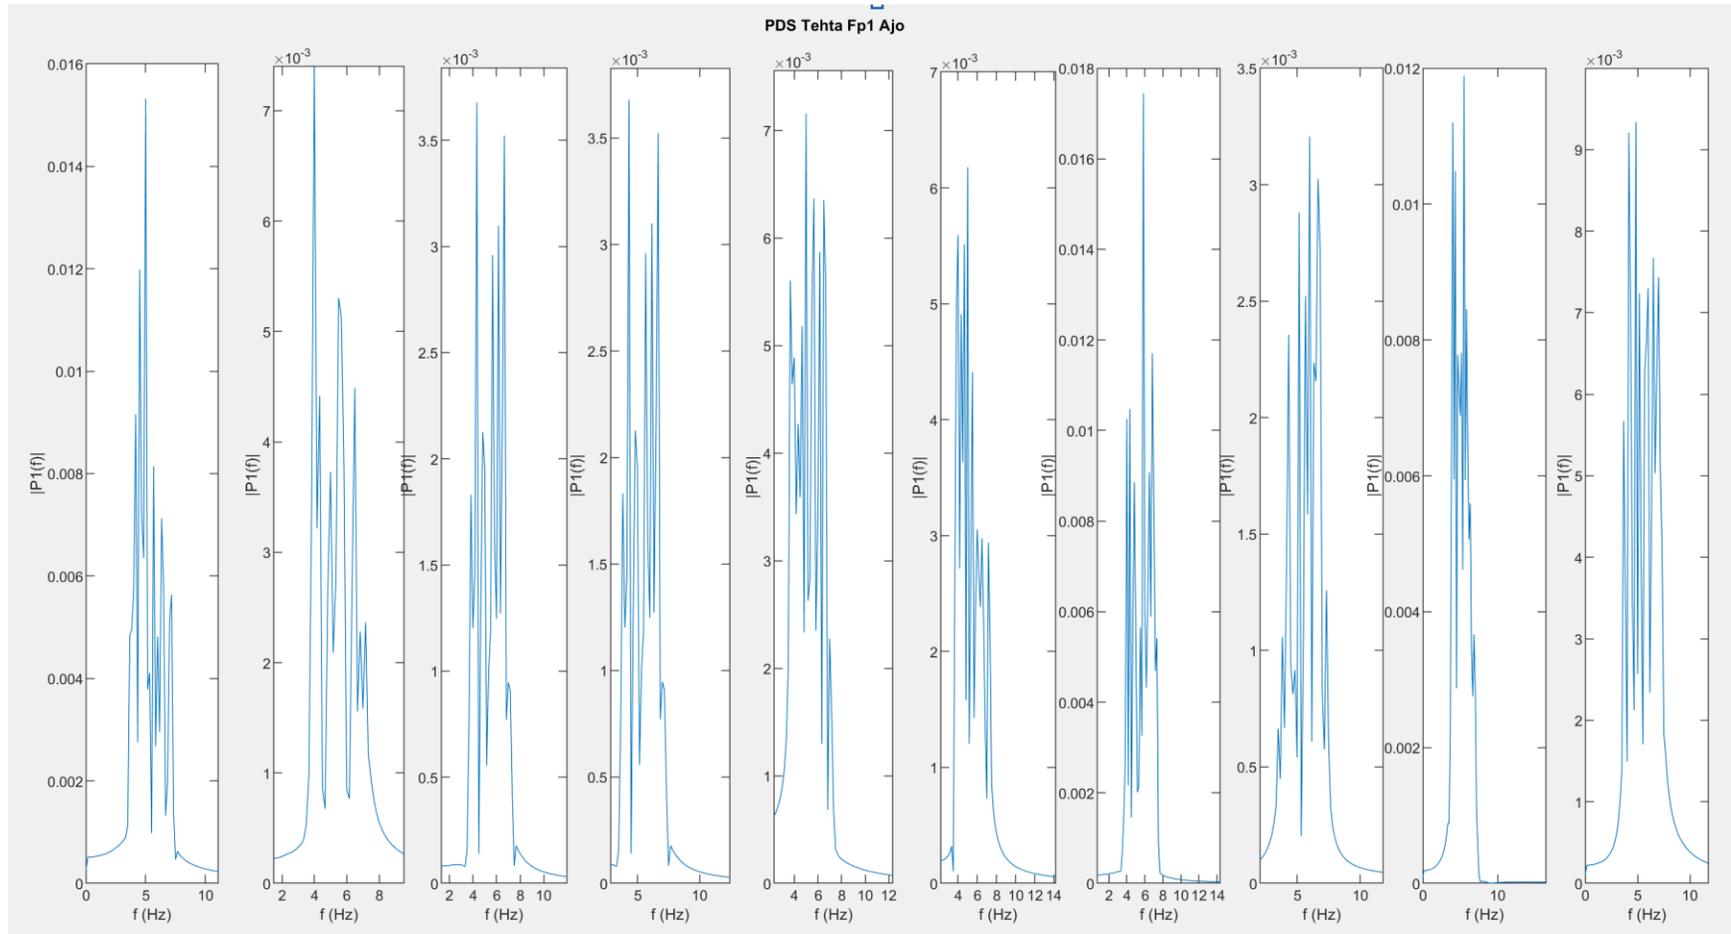


Ilustración 24. PSD Fp1 correspondiente a 10 sujetos durante el OERP de olfacción Ajo.

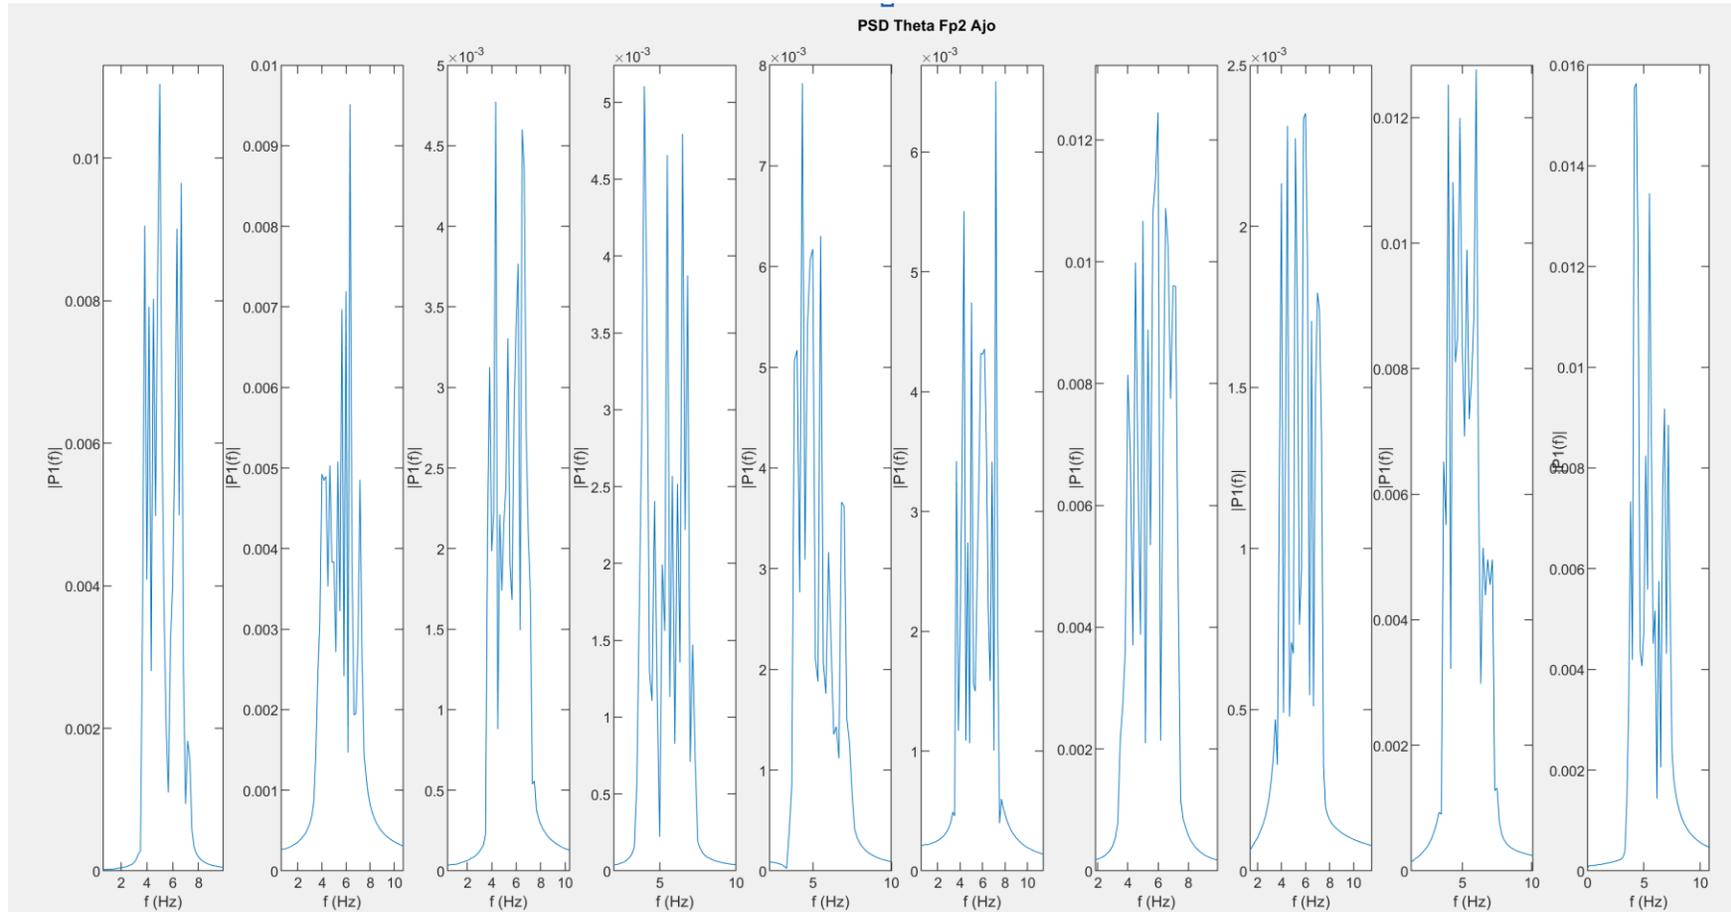


Ilustración 25. PSD Fp2 correspondiente a 10 sujetos durante el OERP de olfacción Ajo.

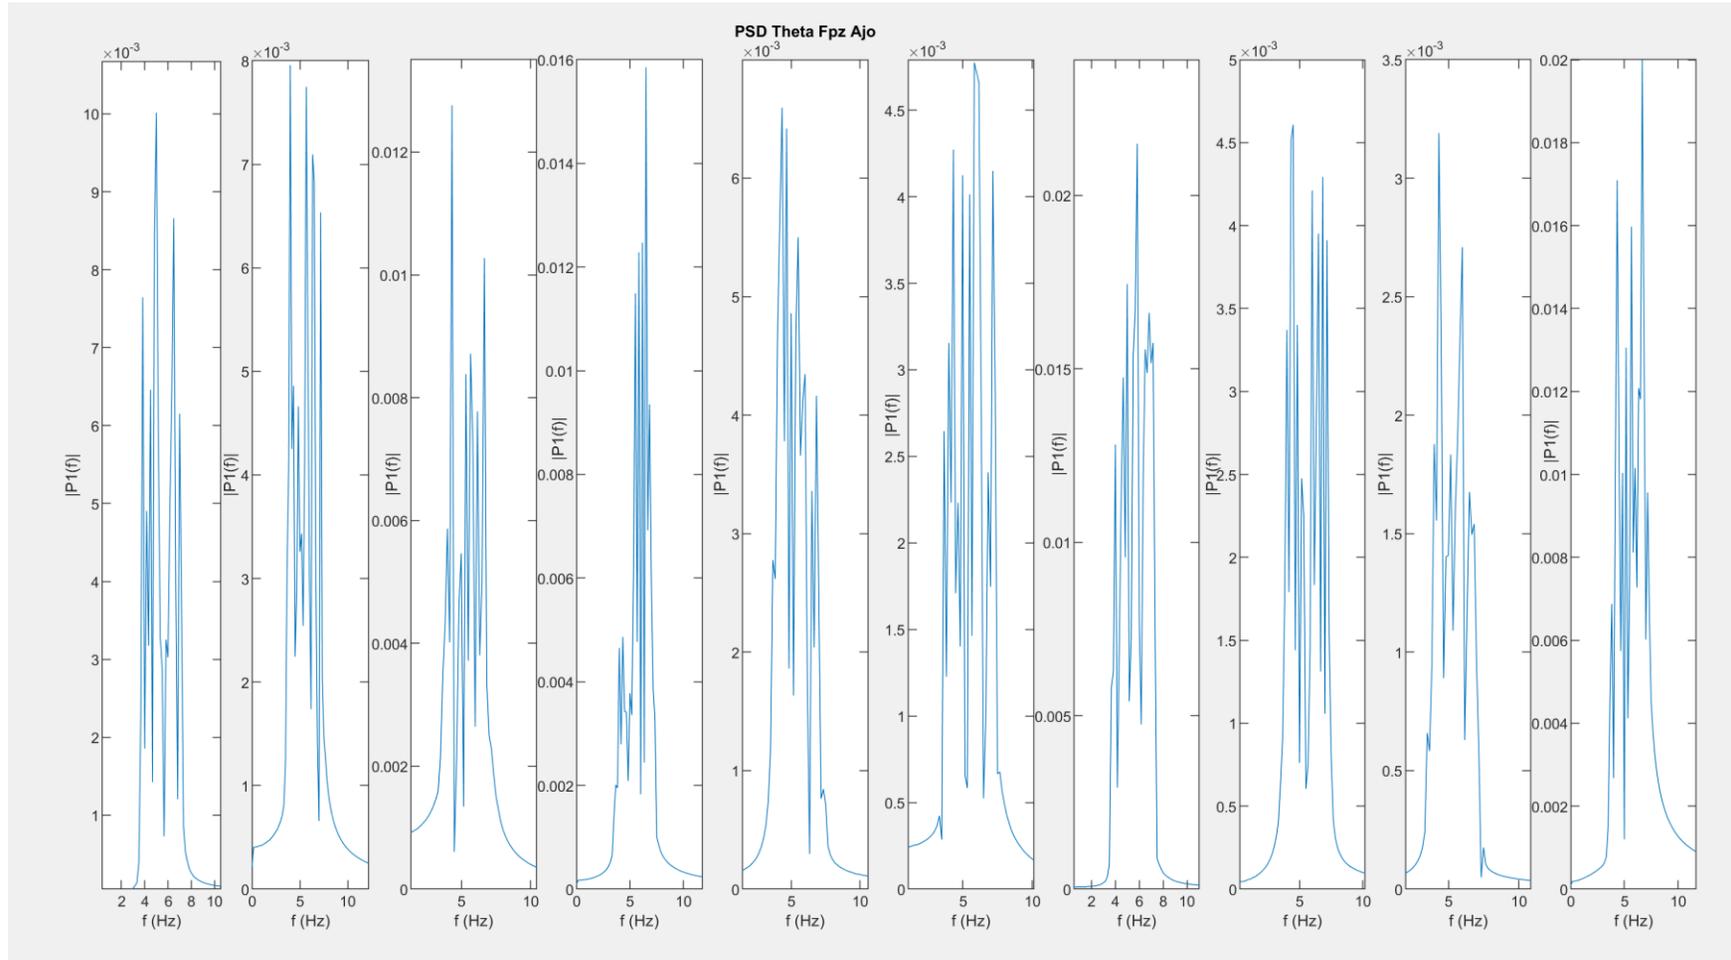


Ilustración 26. PSD Fpz correspondiente a 10 sujetos durante el OERP de olfacción Ajo.

Medidas de tendencia central						
Medida estadística	Ajo Fp1		Ajo Fp2		Ajo Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Des. Estándar	0,654317291	0,004962071	1,073674674	0,004201704	0,975769321	0,006725771
Media	4,98002	0,008530536	5,32978	0,00880397	5,14657	0,010526161
Moda	4,99667	0,00367861	4,33045	NA	4,33045	0,00460836
Moda	NA	NA	NA	NA	5,82945	NA
Moda	NA	NA	NA	NA	4,497	NA

Tabla 10. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a ajo, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

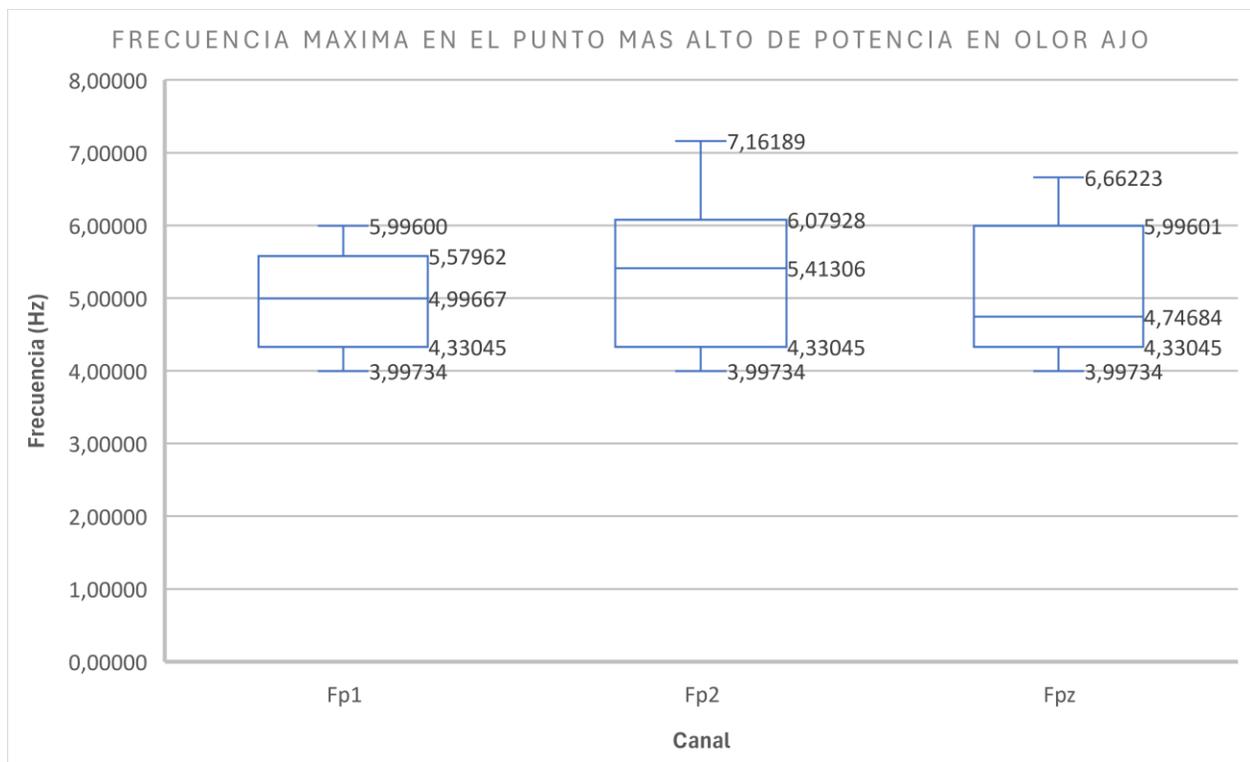


Ilustración 27. Diagrama de cajas y bigotes de la frecuencia máxima en el punto mas alto de potencia para Fp1, Fp2 y Fpz en el olor a Ajo.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Ajo, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp1 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 4,99667 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 4.98002 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,0654317291 sugiriendo una homogeneidad de

la frecuencia dominante, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia identifica una moda de 0,00367861 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 0,008530536 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,004962071 sugiriendo una homogeneidad de la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Ajo, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp2 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 4,33045 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,32978 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,073674674 sugiriendo que las frecuencias dominantes son relativamente homogéneos y se desvían en 1 unidad de la media, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, Se obtiene una media de 0,00880397 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,004201704 sugiere que la densidad espectral de potencia es homogénea, con poca variabilidad y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Ajo, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fpz la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica tres modas de 4,33045, 5,82945 y 4,497 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,14657 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,975769321 sugiriendo una homogeneidad de las frecuencia dominante, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia identifica una moda de 0,00460836 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 0,010526161 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,006725771 sugiriendo una homogeneidad de la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Atreves de la implementación de la FFT y posteriormente la representación del PSD de la señal se

identificó que el pico de mayor densidad espectral para los 10 sujetos analizados en esta investigación se comportó entre los siguientes rangos:

Para la olfacción a Ajo, la frecuencia dominante en Fp1 [3,99734 5,99600]Hz, mientras tanto la densidad espectral de potencia en Fp1[0,01744 0,0174426] dBm/Hz.

la frecuencia dominante en Fp2 [3,99734 7,16189]Hz, mientras tanto la densidad espectral de potencia en Fp2 [0,00233 0,01564] dBm/Hz.

la frecuencia dominante en Fpz [3,99734 6,66223]Hz, mientras tanto la densidad espectral de potencia en Fpz [0,00319 0,02149] dBm/Hz.

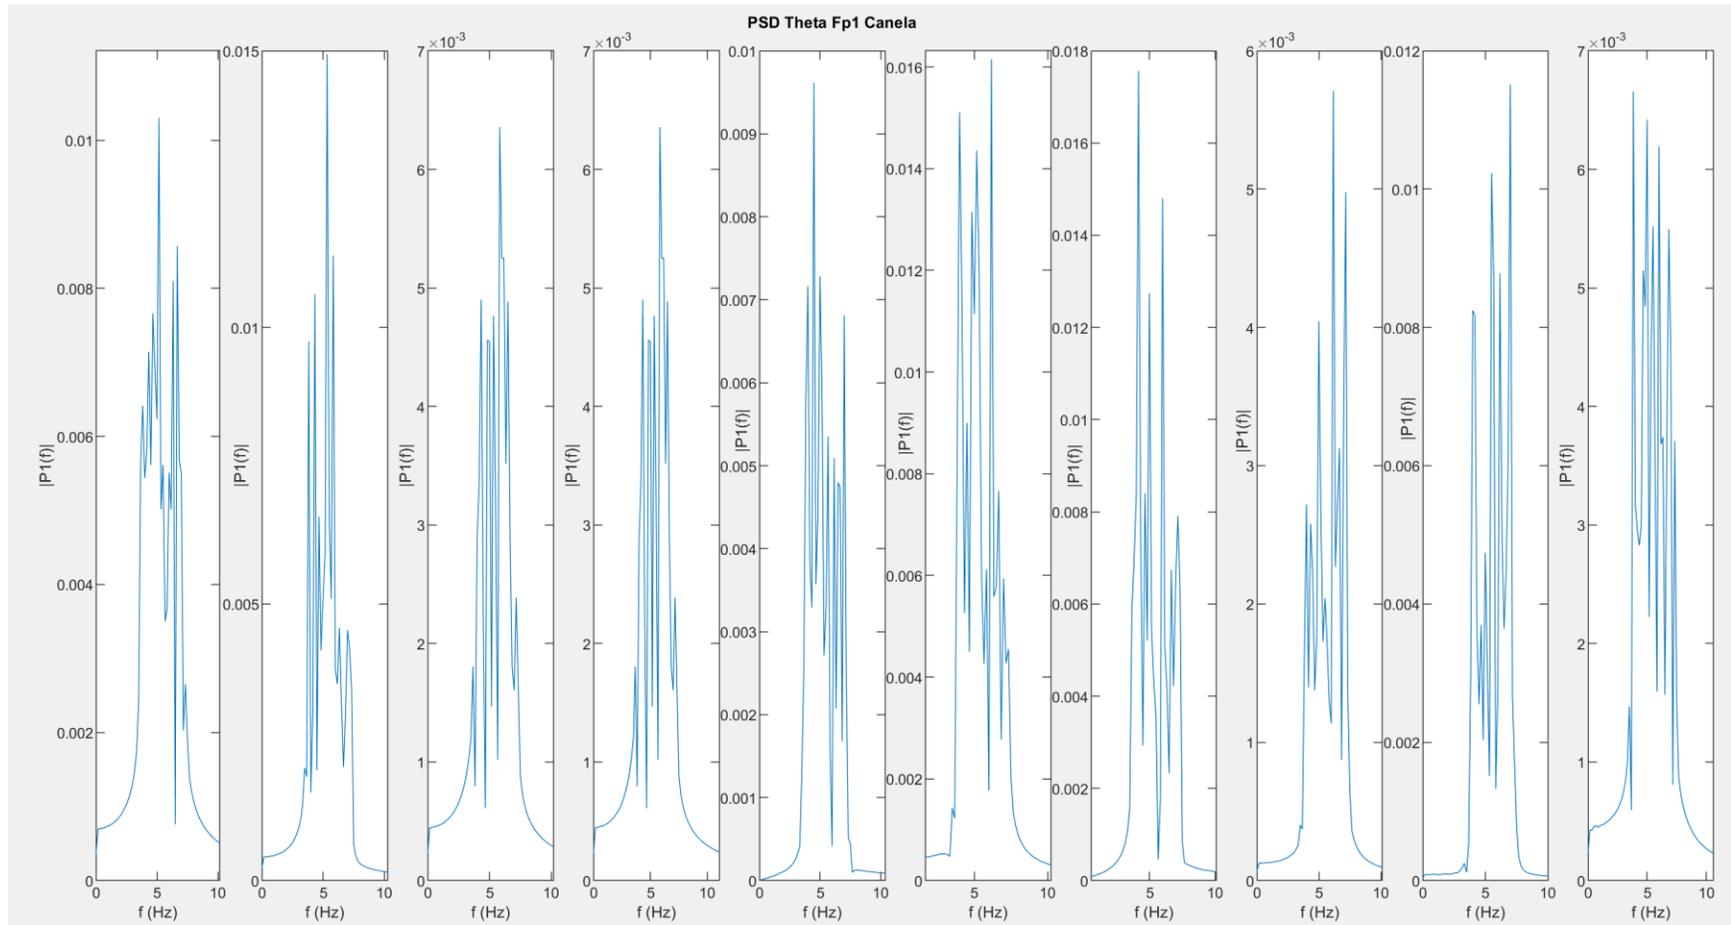


Ilustración 28. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Canela.

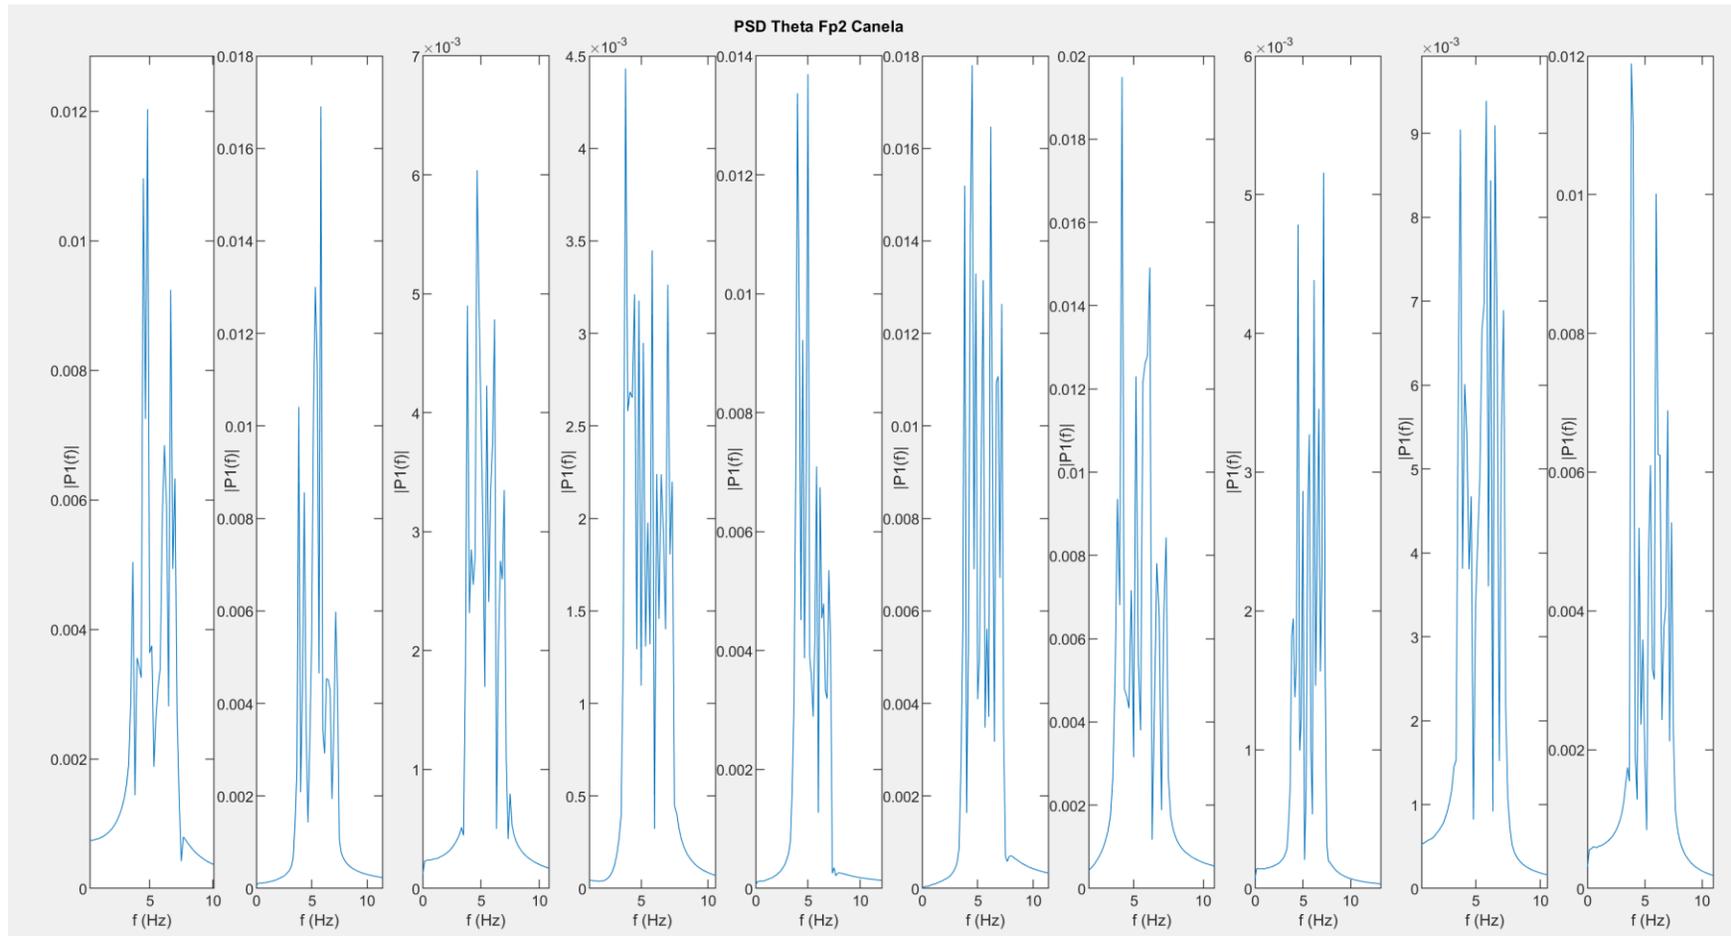


Ilustración 29. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Canela.

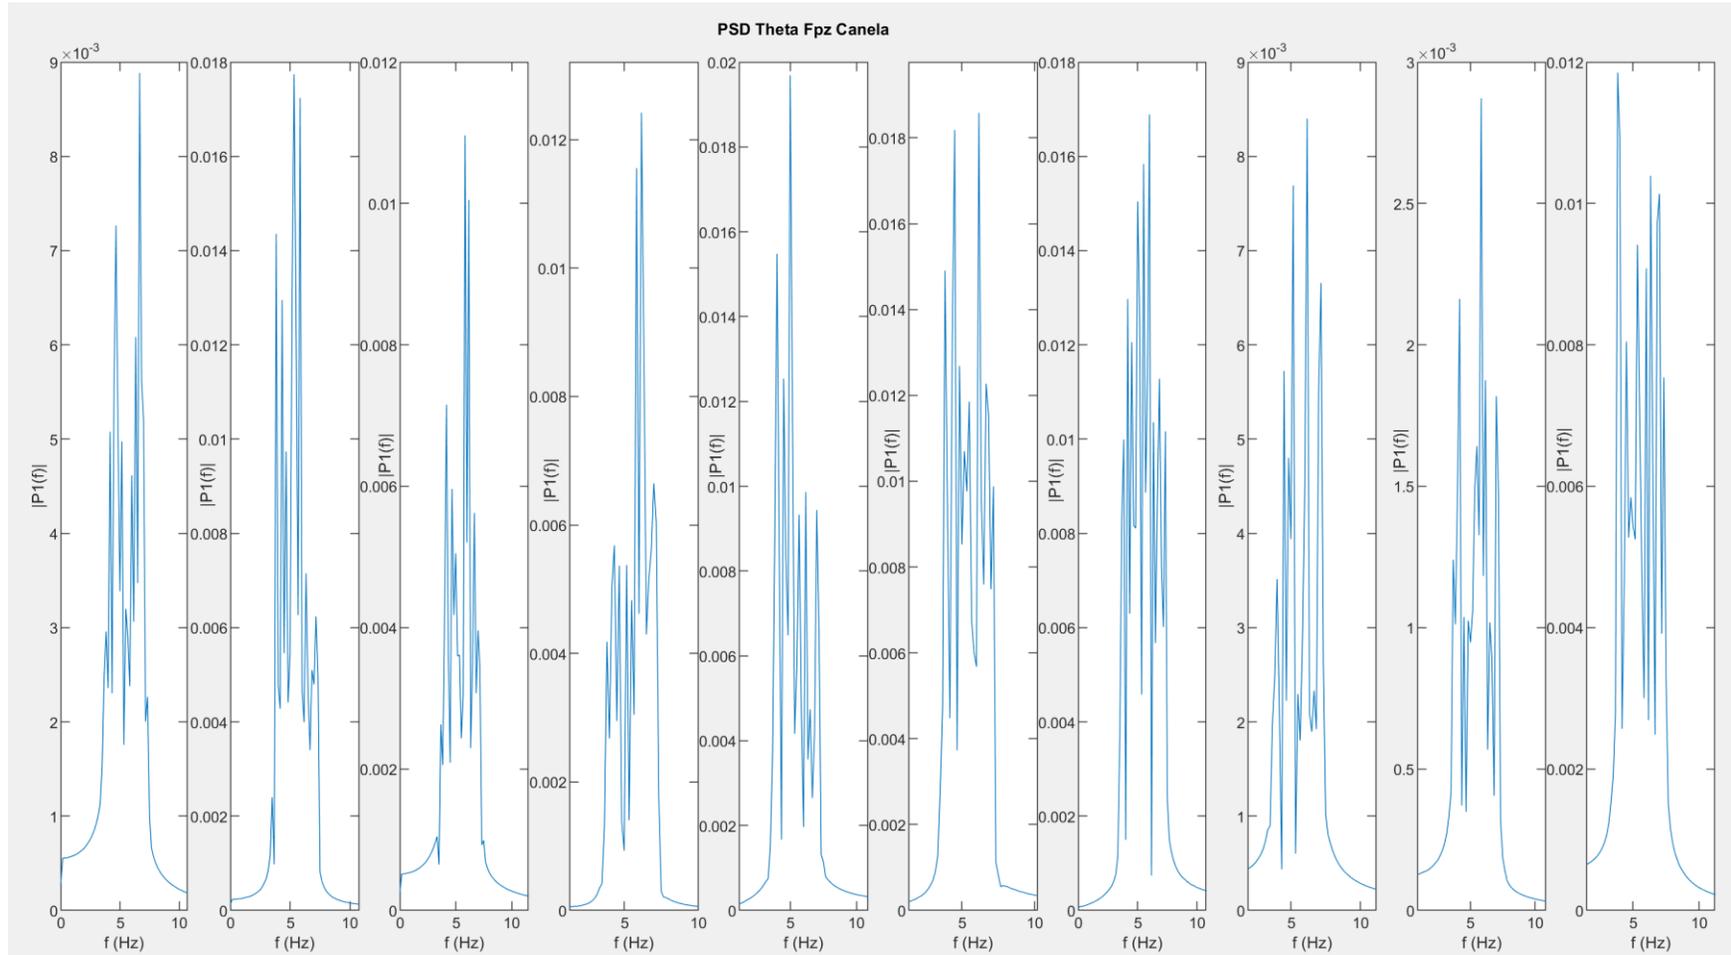


Ilustración 30. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Canela.

Medidas de tendencia central						
Medida estadística	Canela Fp1		Canela Fp2		Canela Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Des. Estándar	0,996864774	0,004416167	1,04693319	0,005397361	0,901439459	0,005371687
Media	5,39640	0,010517345	4,96336	0,011683959	5,79610	0,012829458
Moda	5,82945	0,00635624	5,82945	NA	5,82945	NA
Moda	6,16256	NA	3,83078	NA	6,16256	NA

Tabla 11 Medidas de tendencia central durante OERP del ritmo Theta de olfacción a canela, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

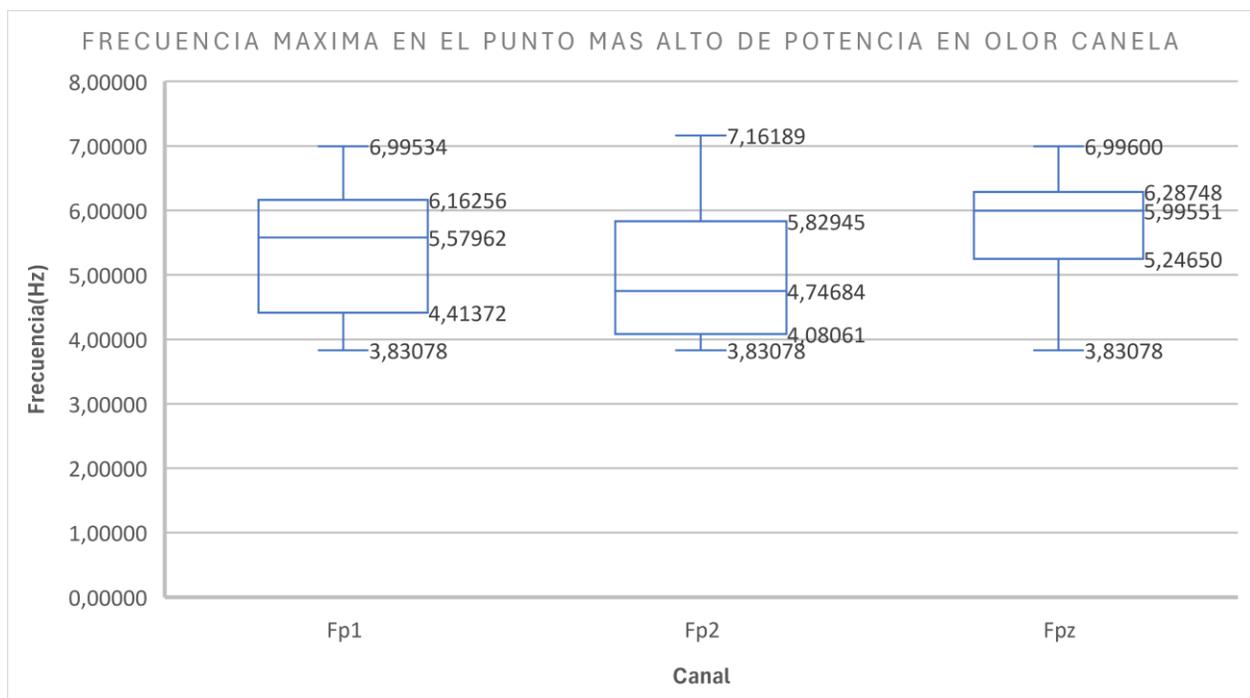


Ilustración 31. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Canela.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Canela, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp1 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal de 5,82945 y 6,16256 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,39640 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,996864774 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media. Así mismo en la

densidad espectral de potencia identifica una moda de 0,00635624 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 0,010517345 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,004416167 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Canela, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp2 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal 5,82945 y 3,83078 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 4,96336 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,04693319 sugiriendo que los datos son relativamente homogéneos y se desvían en 1 unidad de la media, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, Se obtiene una media de 0,011683959 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,005397361 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Canela, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fpz la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal de 5,82945 y 6,16256 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,79610 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,901439459 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, se obtiene una media de 0,012829458 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,005371687 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Atreves de la implementación de la FFT y posteriormente la representación del PSD de la señal se identificó que el pico de mayor densidad espectral para los 10 sujetos analizados en esta investigación se comportó entre los siguientes rangos:

Para la olfacción a Canela, la frecuencia dominante en Fp1 [3,83078 6,99534]Hz, mientras tanto la densidad espectral de potencia en Fp1 [0,01756 0,0175648] dBm/Hz.

la frecuencia dominante en Fp2 [3,83078 7,16189]Hz, mientras tanto la densidad espectral de potencia en Fp2 [0,00443 0,01950].

la frecuencia dominante en Fpz [3,83078 6,99600]Hz, mientras tanto la densidad espectral de potencia en Fpz [0,00287 0,01969] dBm/Hz.

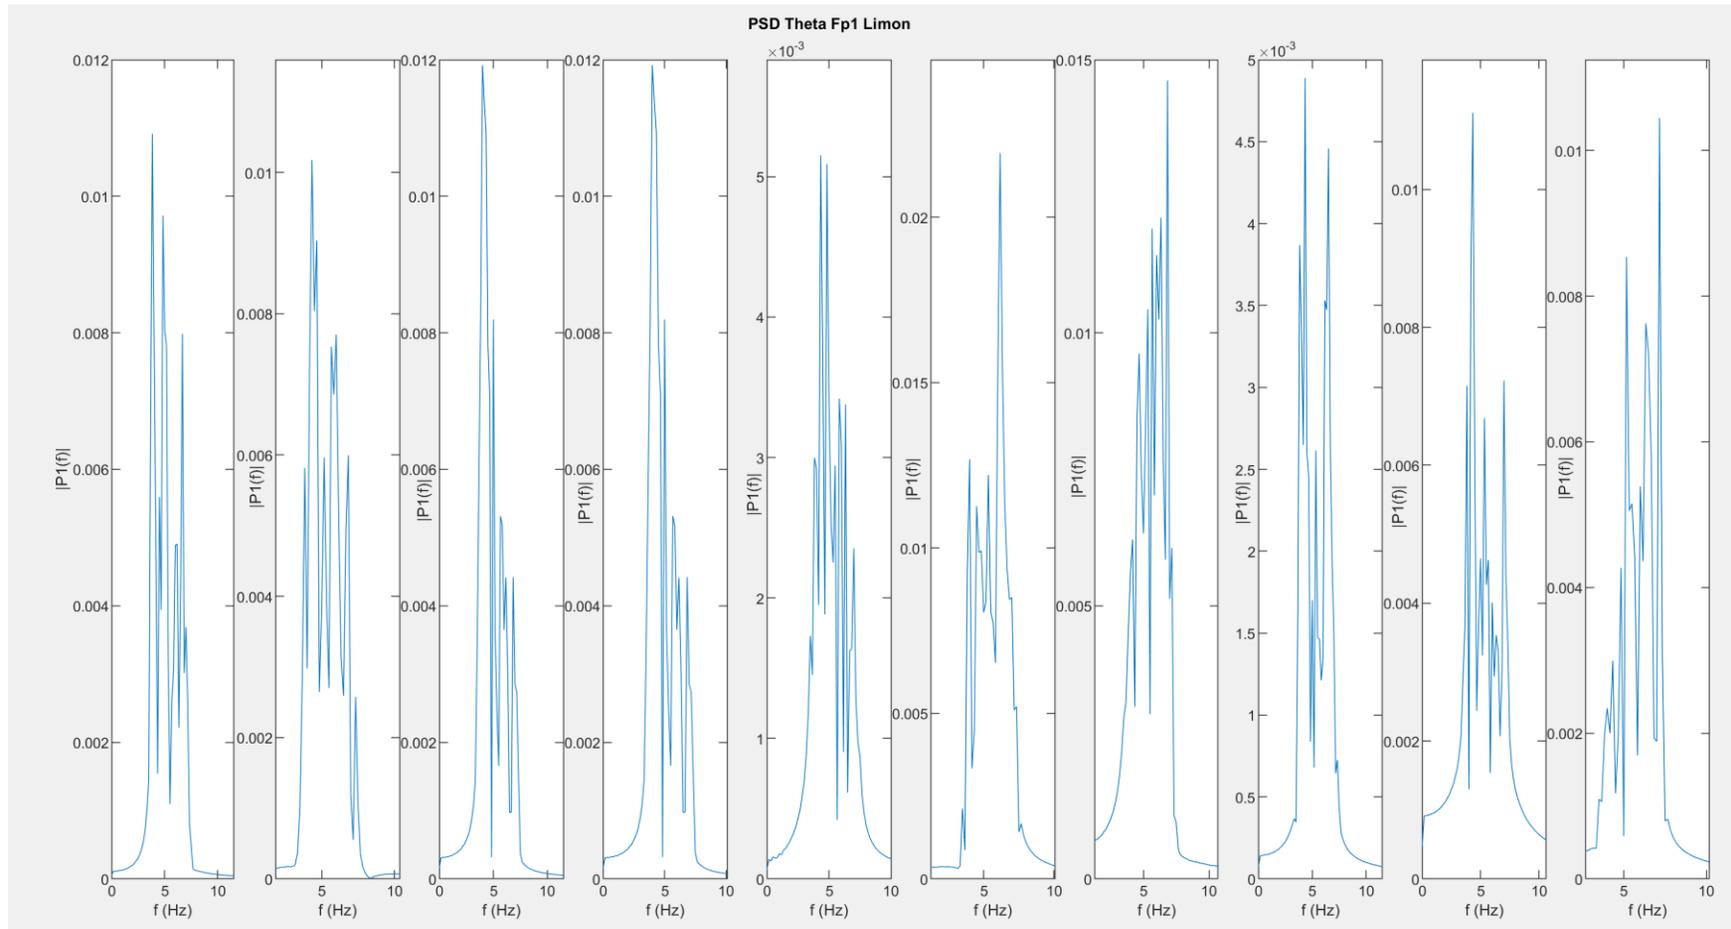


Ilustración 32. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Limón.

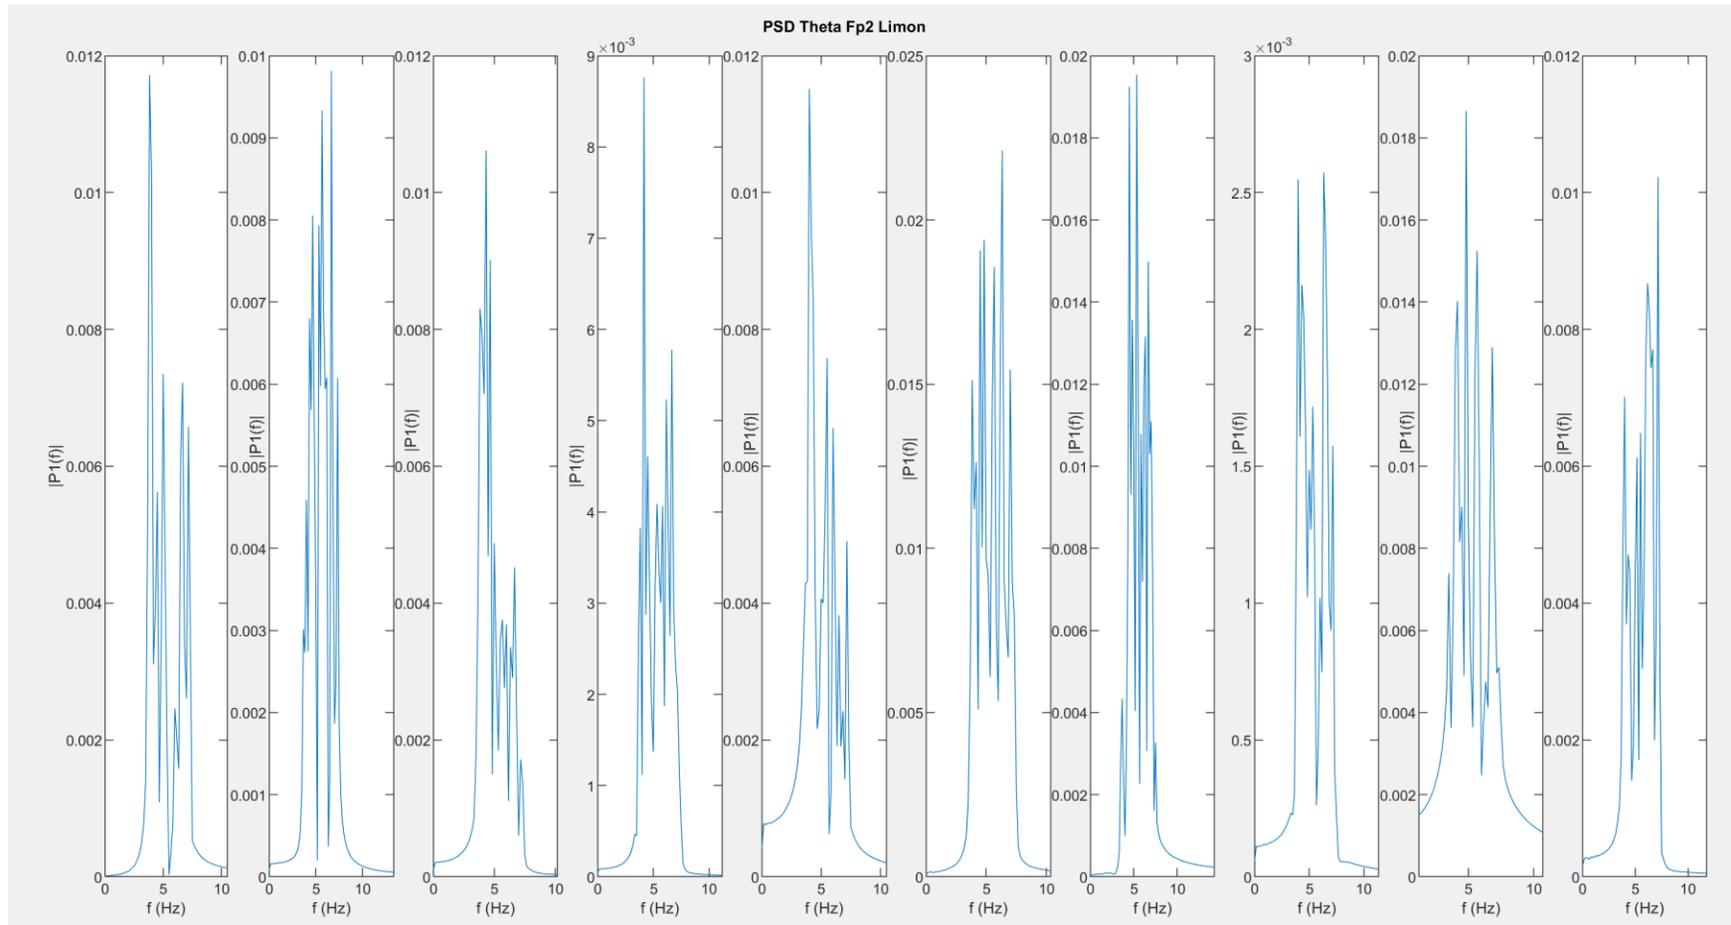


Ilustración 33. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Limón.

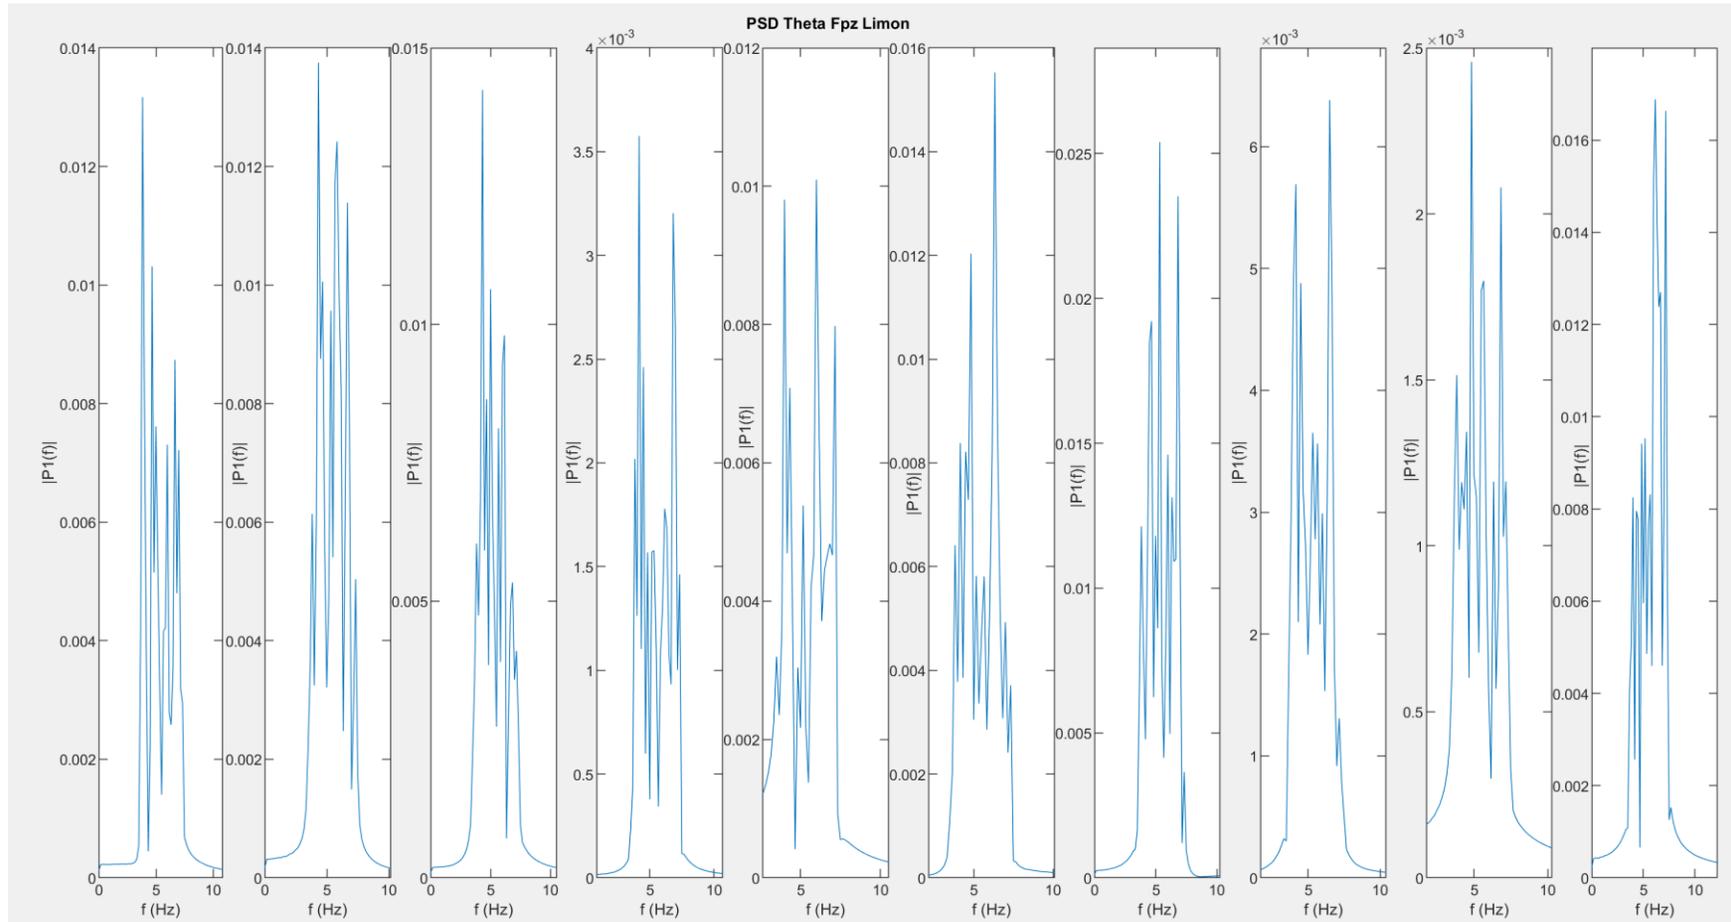


Ilustración 34. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Limón.

Medidas de tendencia central						
Medida estadística	Limón Fp1		Limón Fp2		Limón Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Des. Estándar	1,268825933	0,00478382	1,234773602	0,005866653	1,006872982	0,006848923
Media	4,92995	0,011308929	5,29737	0,012552315	5,17987	0,012147898
Moda	4,33045	0,0119215	6,32911	NA	4,33045	NA
Moda	NA	NA	NA	NA	NA	NA

Tabla 12. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a Limón, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

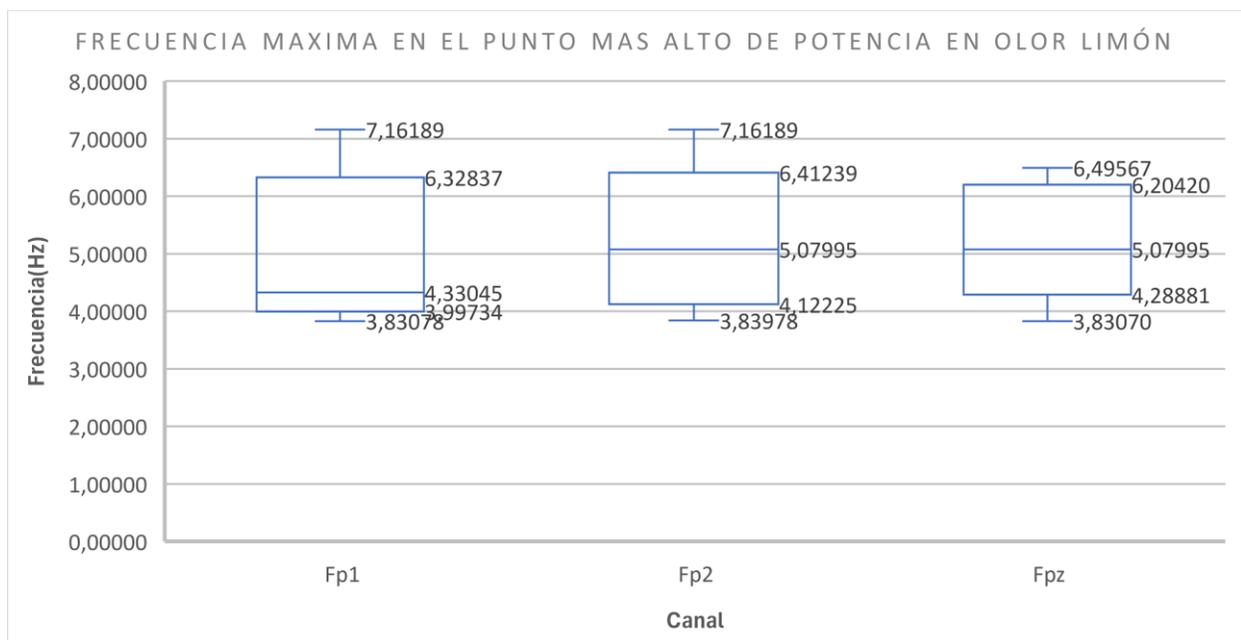


Ilustración 35. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Limón.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Limón, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp1 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 4,33045 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 4,92995 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,268825933 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia identifica una moda de 0,0119215 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 0,011308929 dBm/Hz denotando el promedio de la frecuencia en

la que se comportan los datos y una desviación estándar de 0,00478382 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Limón, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp2 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda 6,32911 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,29737 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,234773602 sugiriendo que los datos son relativamente homogéneos y se desvían en 1 unidad de la media, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, Se obtiene una media de 0,012552315 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,005866653 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Limón, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fpz la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 4,33045 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,17987 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,006872982 sugiriendo una relativa homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, se obtiene una media de 0,0121447898 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,006848923 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Atreves de la implementación de la FFT y posteriormente la representación del PSD de la señal se identificó que el pico de mayor densidad espectral para los 10 sujetos analizados en esta investigación se comportó entre los siguientes rangos:

Para la olfacción a Limón, la frecuencia dominante en Fp1 [3,83078 7,16189]Hz, mientras tanto la densidad espectral de potencia en Fp1[0,00489 0,0219342] dBm/Hz.

la frecuencia dominante en Fp2 [3,83978 7,16189]Hz, mientras tanto la densidad espectral de potencia en Fp2 [0,00257 0,02211] dBm/Hz.

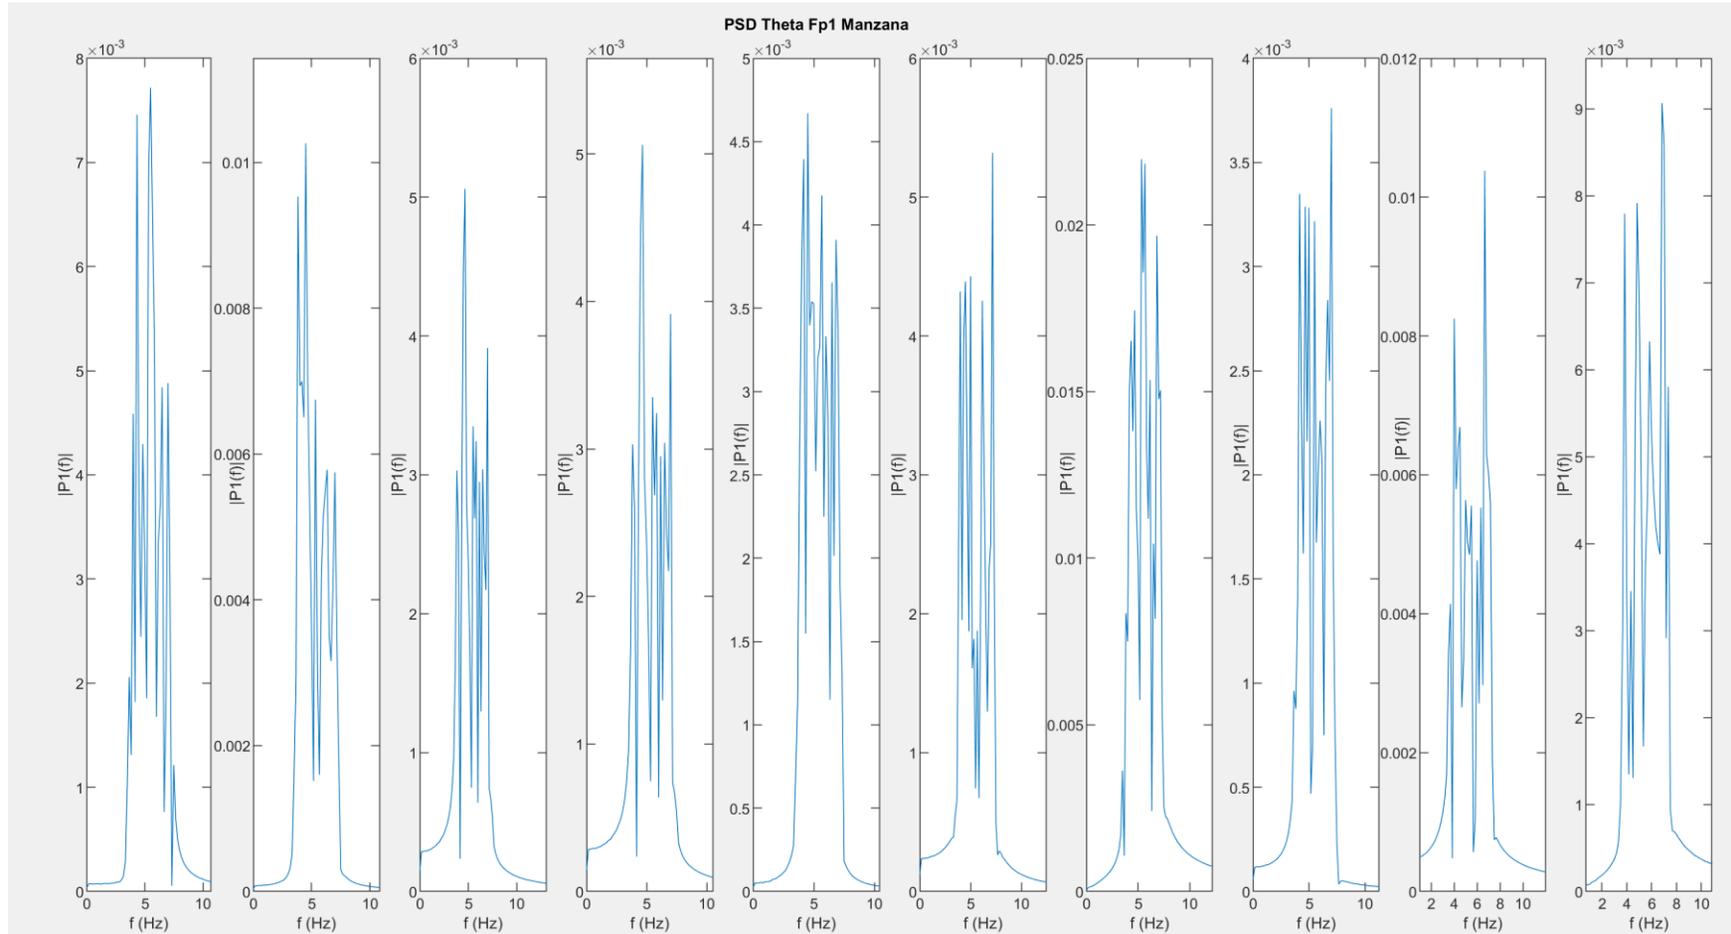


Ilustración 36. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Manzana.

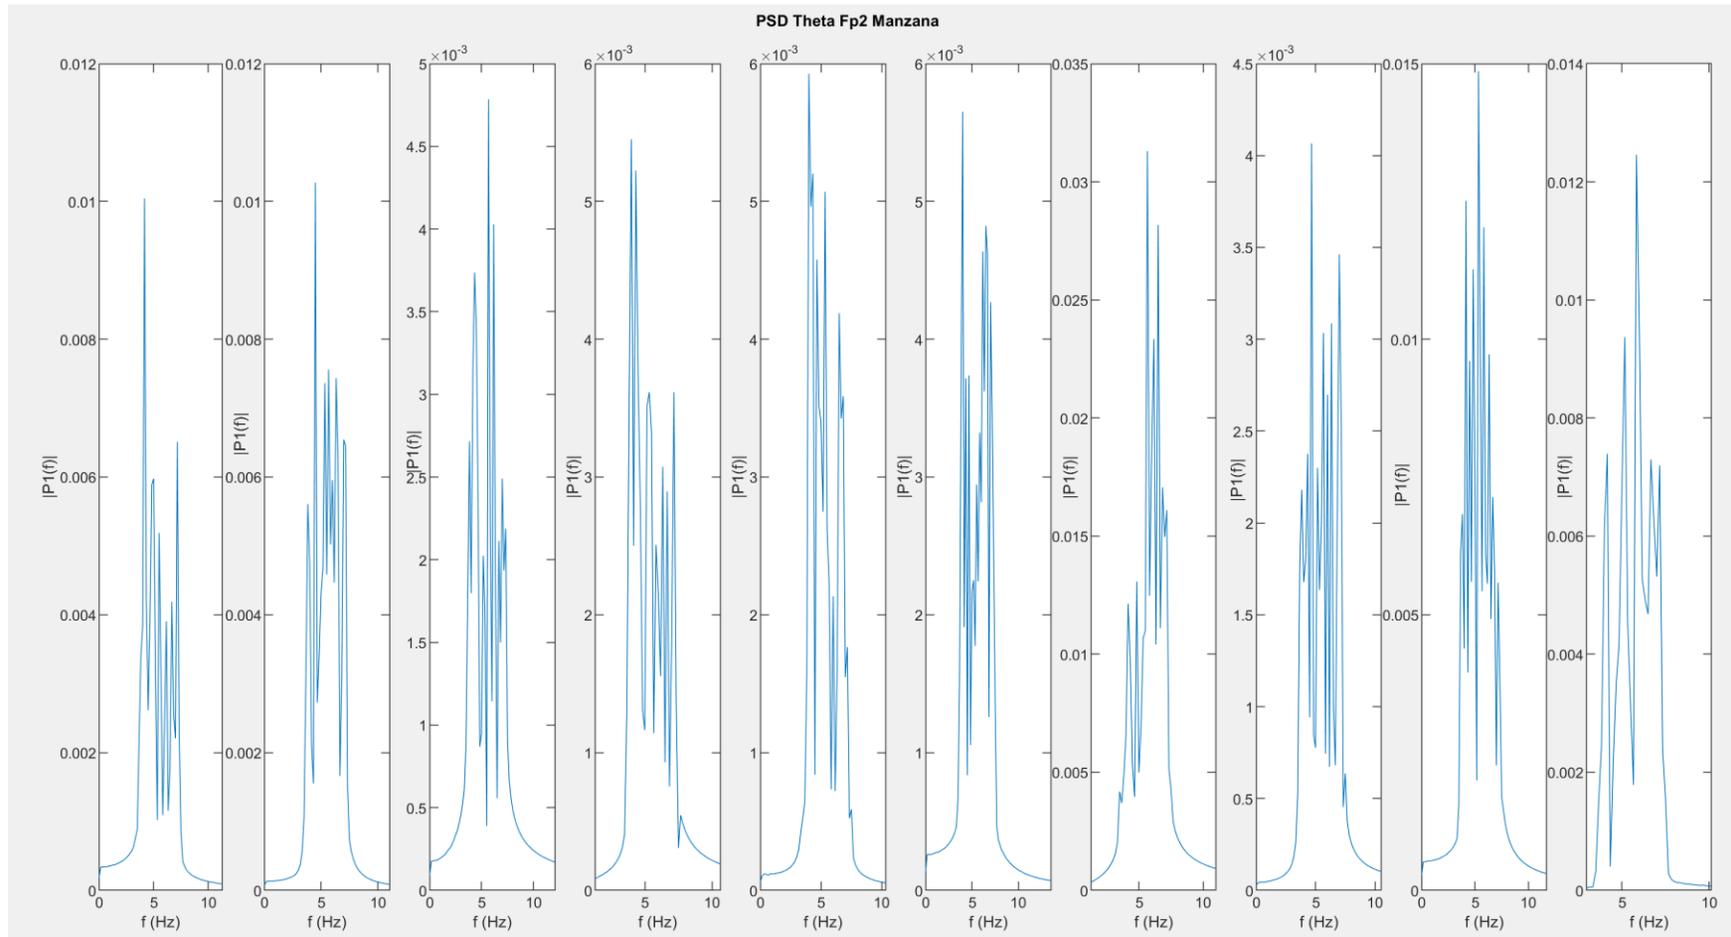


Ilustración 37. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Manzana.

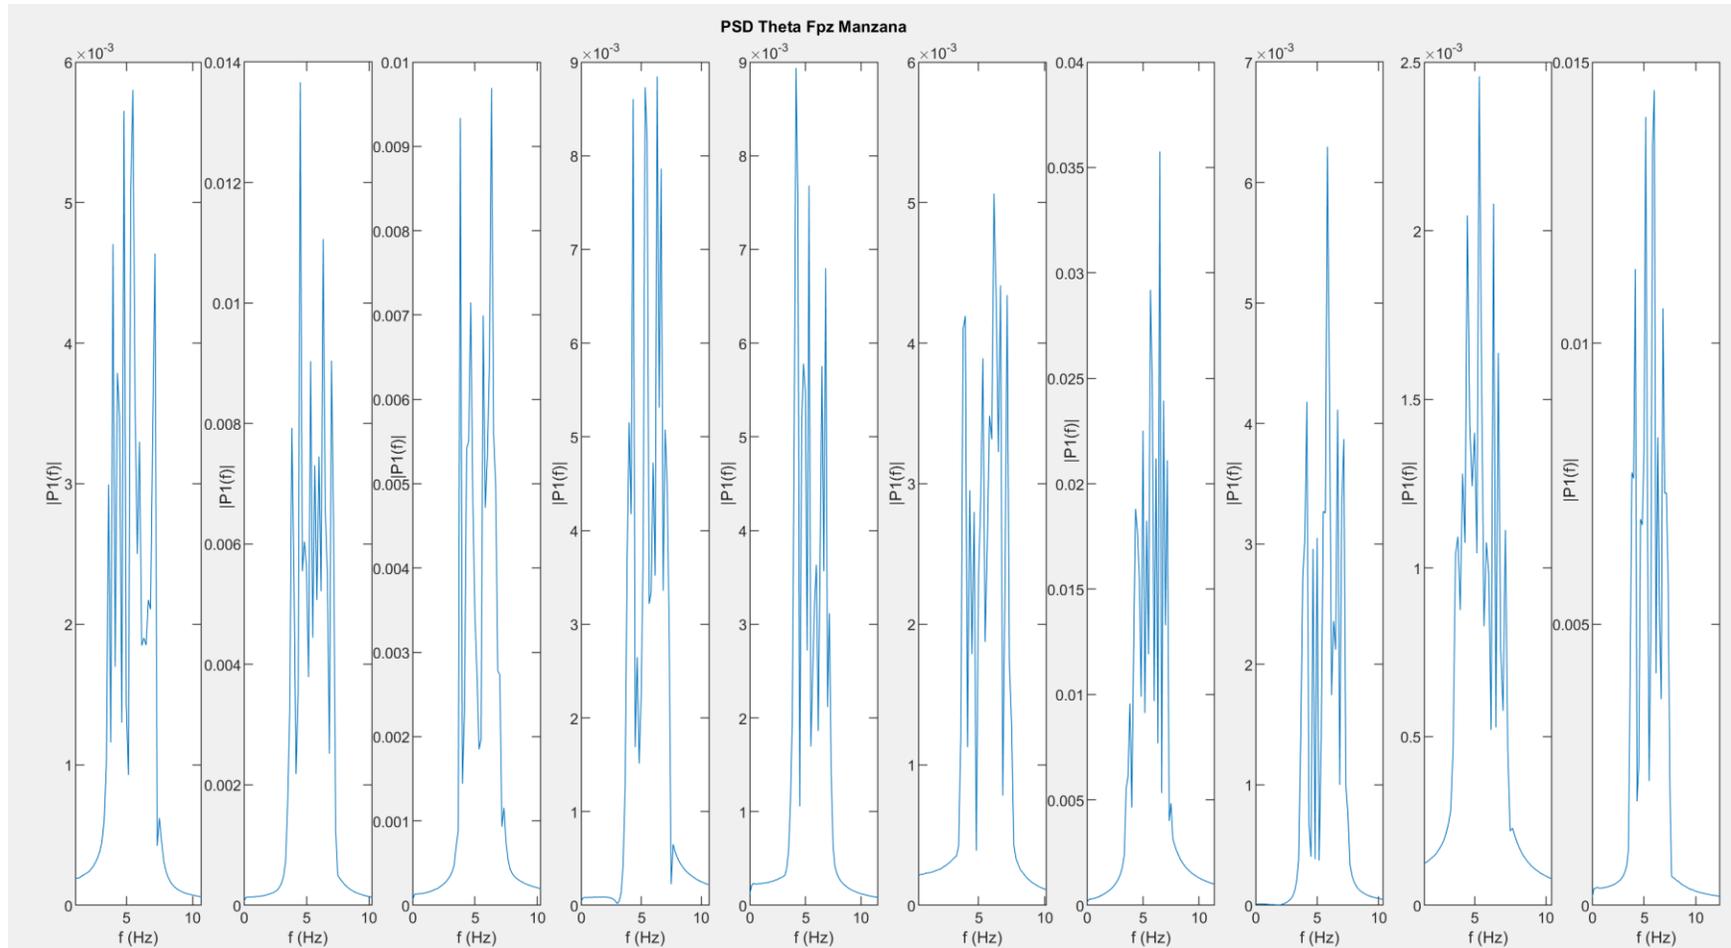


Ilustración 38. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Manzana.

Medidas de tendencia central						
Medida estadística	Manzana Fp1		Manzana Fp2		Manzana Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Varianza	1,110510078	0,005333572	0,765342108	0,008163148	0,796840775	0,009428052
Media	5,71286	0,008313558	4,78005	0,010481707	5,66289	0,011101833
Moda	4,497	0,0050616	3,99734	NA	6,32911	NA
Moda	4,66356	NA	NA	NA	NA	NA

Tabla 13. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a manzana, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondierdes a Fp1, Fp2 y Fpz.

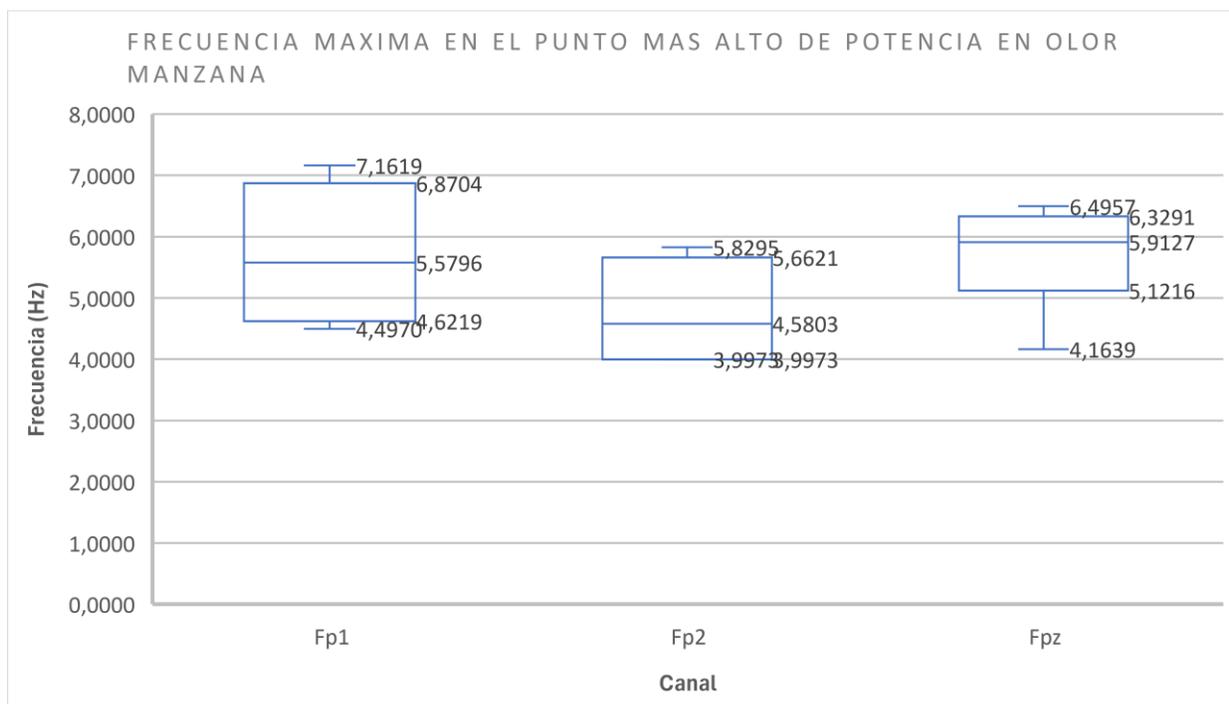


Ilustración 39. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Manzana.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Manzana, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp1 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal de 4,497 y 4,66356 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,71286 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,110510078 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media. Así mismo en la

densidad espectral de potencia identifica una moda de 0,0050616 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 0,008313558 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,005333572 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Manzana, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp2 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda 3,99734 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 4,78005 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,765342108 sugiriendo que los datos son homogéneos, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, Se obtiene una media de 0,008163148 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,010481707 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Manzana, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fpz la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 6,32911 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,66289 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,008163148 sugiriendo homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, se obtiene una media de 0,010481707 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,008163148 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Atreves de la implementación de la FFT y posteriormente la representación del PSD de la señal se identificó que el pico de mayor densidad espectral para los 10 sujetos analizados en esta investigación se comportó entre los siguientes rangos:

Para la olfacción a Manzana, la frecuencia dominante en Fp1 [4,49700 7,16189]Hz, mientras tanto la densidad espectral de potencia en Fp1 [0,00376 0,02184] dBm/Hz.

la frecuencia dominante en Fp2 [3,99734 5,82945]Hz, mientras tanto la densidad espectral de potencia en Fp2 [0,00407 0,03130] dBm/Hz.

la frecuencia dominante en Fpz [4,16389 6,49567]Hz, mientras tanto la densidad espectral de potencia en Fpz [0,00246 0,03575] dBm/Hz.

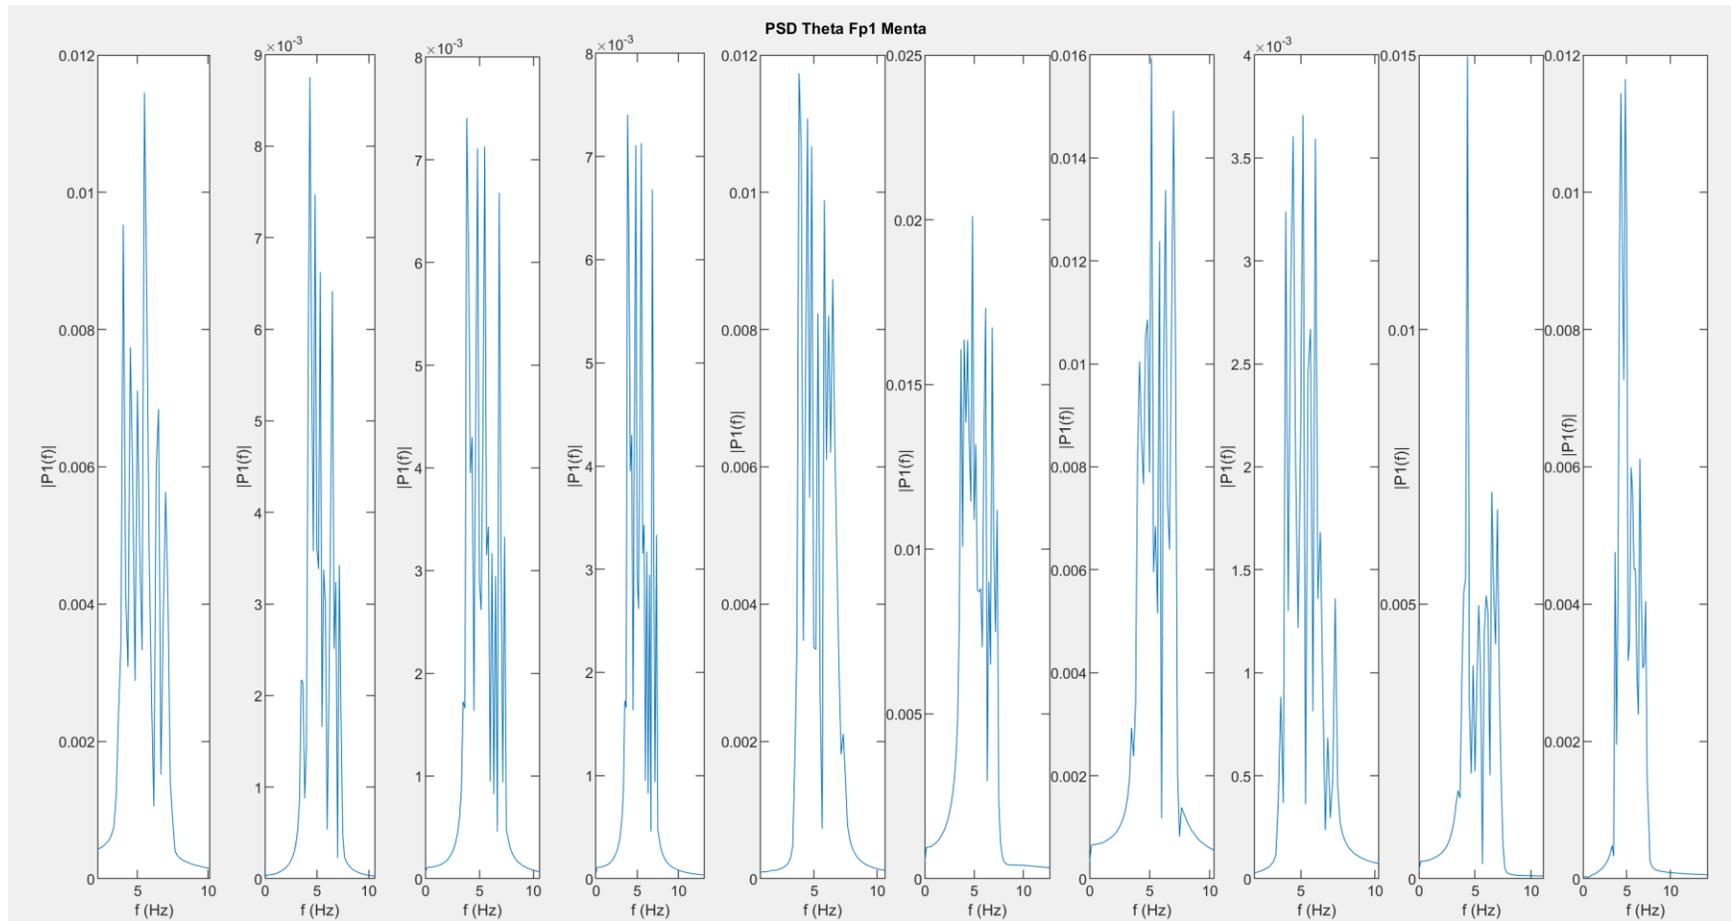


Ilustración 40. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Menta.

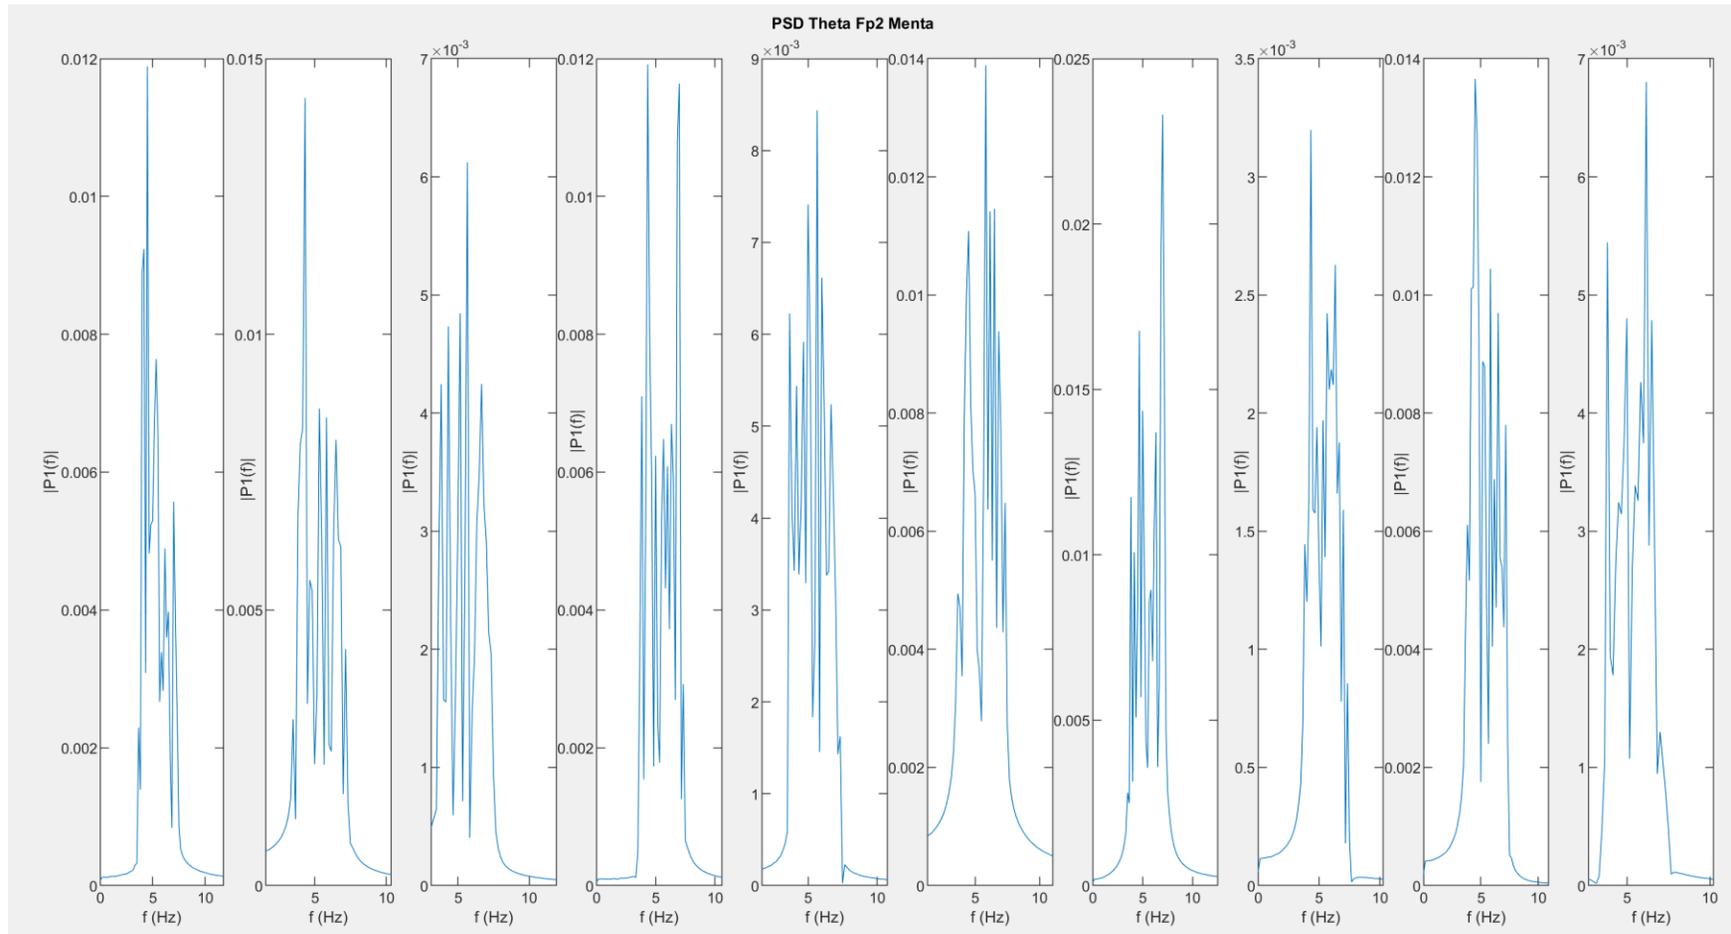


Ilustración 41. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Menta.

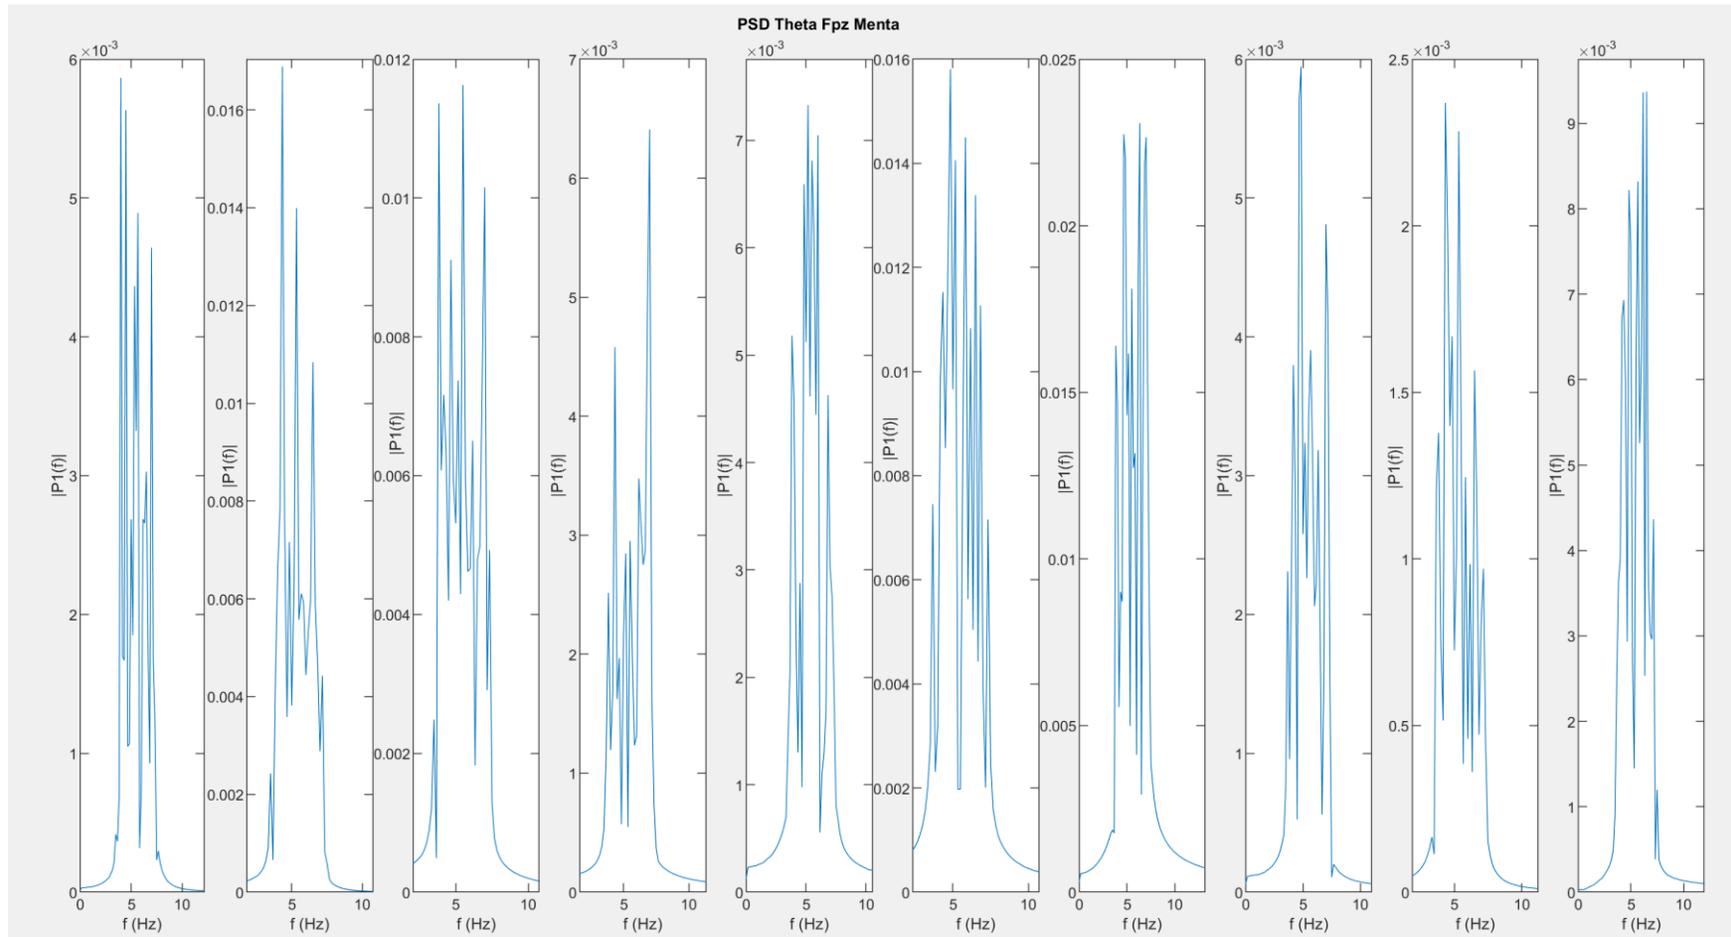


Ilustración 42. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Menta.

Medidas de tendencia central						
Medida estadística	Menta Fp1		Menta Fp2		Menta Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Des. Estándar	0,619223587	0,004800484	0,955822488	0,005700856	0,98457348	0,006368262
Media	4,56362	0,011313599	5,22985	0,011450863	5,24650	0,010468478
Moda	3,83078	0,00740784	4,33045	NA	4,33045	NA
Moda	NA	NA	NA	NA	4,83011	NA

Tabla 14 Medidas de tendencia central durante OERP del ritmo Theta de olfacción a menta, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

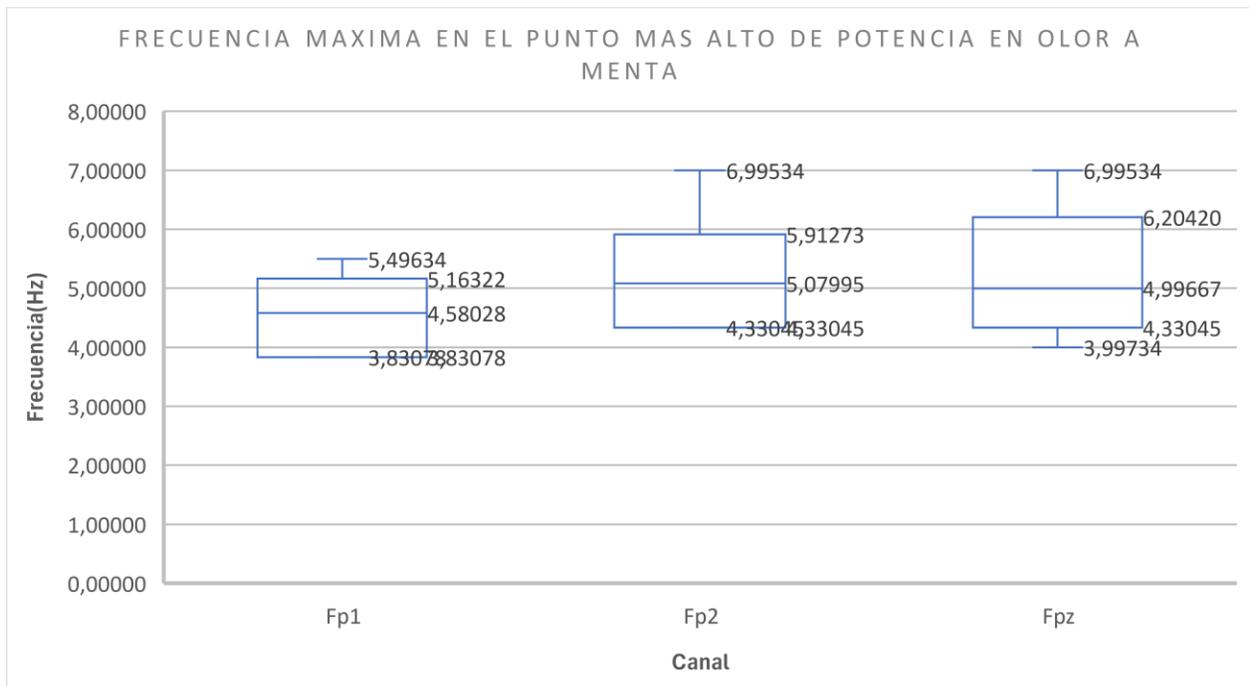


Ilustración 43. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Menta.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Menta, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp1 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 3,83078 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 4,56362 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,619223587 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia identifica una moda de 0,00740784 dBm/Hz denotando una repetitividad en varios

sujetos, Se obtiene una media de 0,011313599 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,00480048 sugiriendo una homogeneidad de los datos, poca variabilidad de los datos y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Menta, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp2 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda 4,33045 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,22985 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,955822488 sugiriendo que los datos son homogéneos y se desvían en 1 unidad de la media, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, Se obtiene una media de 0,011450863 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,005700856 sugiriendo una homogeneidad de la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Menta, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fpz la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal de 4,33045 y 3,83011 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,24650 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,98457348 sugiriendo una homogeneidad de los datos de la frecuencia dominante, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, se obtiene una media de 0,010468478 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,006368262 sugiriendo una homogeneidad en la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Atreves de la implementación de la FFT y posteriormente la representación del PSD de la señal se identificó que el pico de mayor densidad espectral para los 10 sujetos analizados en esta investigación se comportó entre los siguientes rangos:

Para la olfacción a Menta, la frecuencia dominante en Fp1 [3,83078 5,49634]Hz, mientras tanto la densidad espectral de potencia en Fp1[0,00371 0,0201094] dBm/Hz.

la frecuencia dominante en Fp2 [4,33045 5,82945]Hz, mientras tanto la densidad espectral de potencia en Fp2 [0,00407 0,03130] dBm/Hz.

la frecuencia dominante en Fpz [3,99734 6,99534]Hz, mientras tanto la densidad espectral de potencia en Fpz [0,00237 0,02308] dBm/Hz.

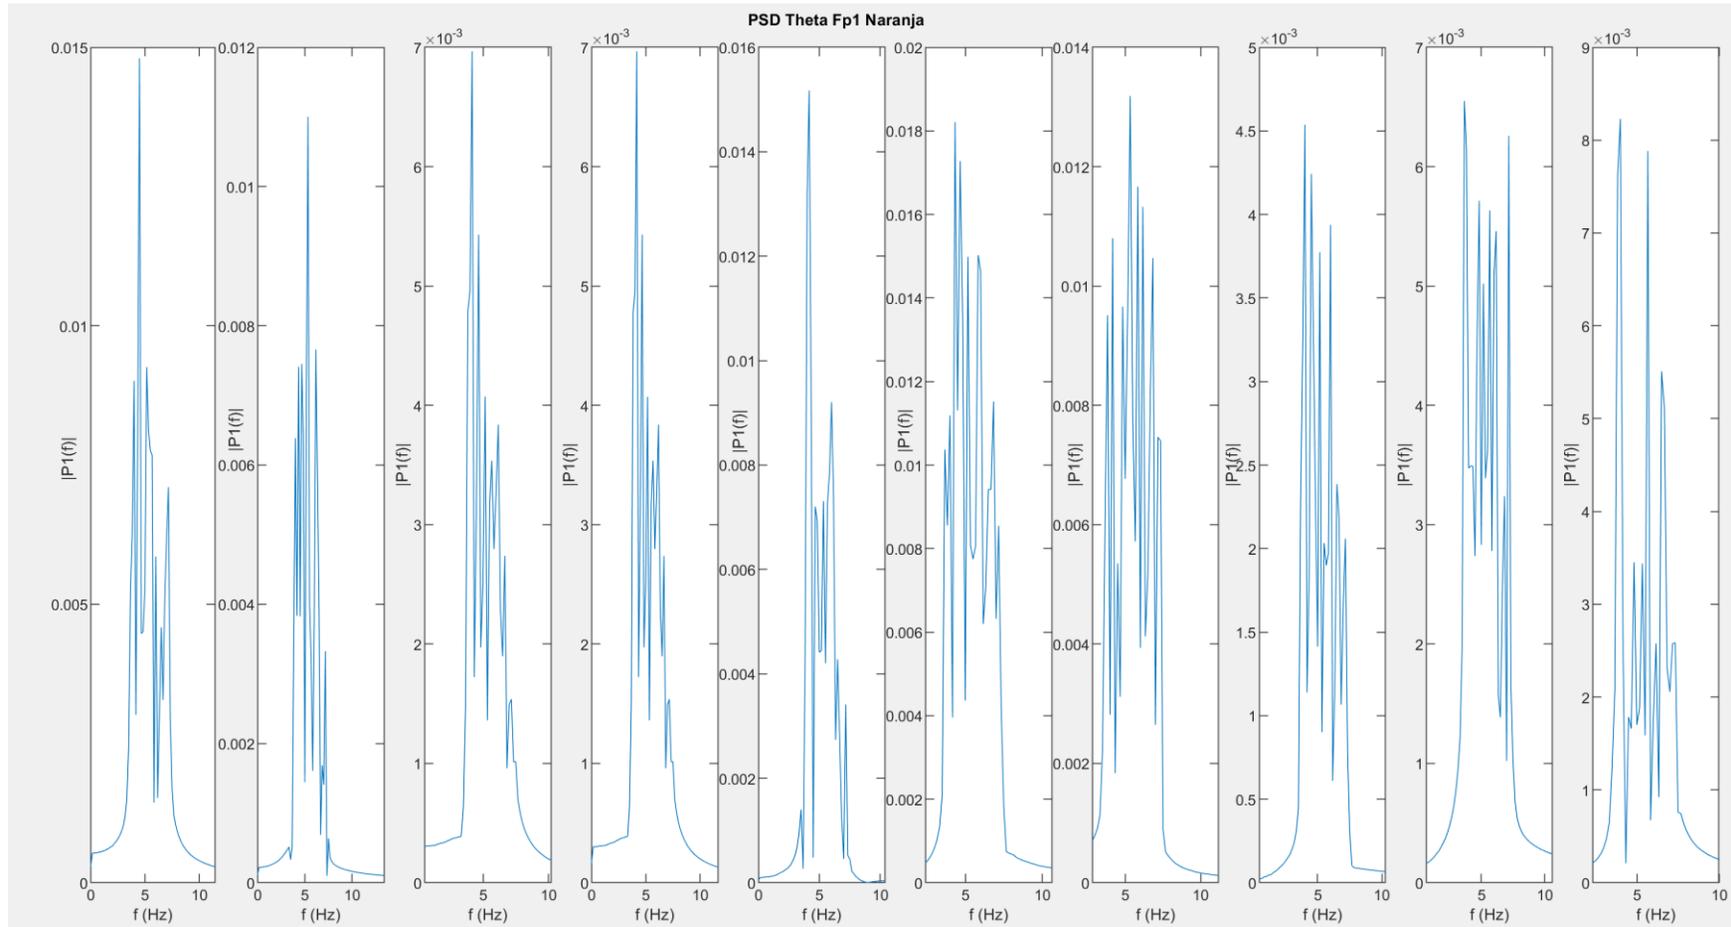


Ilustración 44. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Naranja.

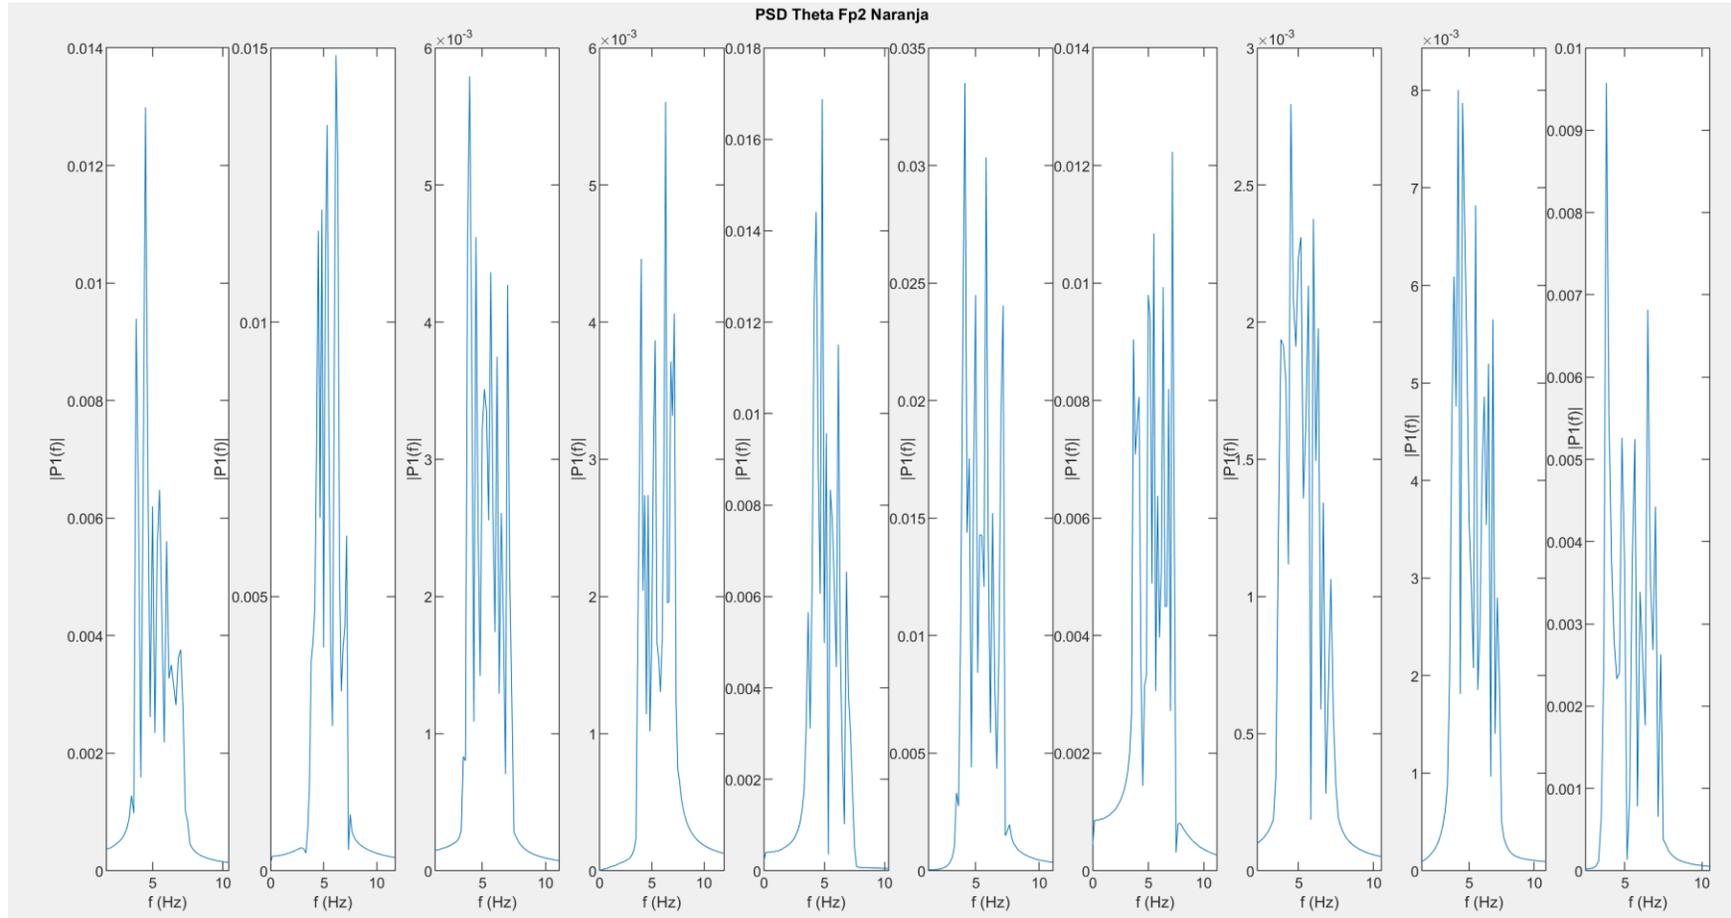


Ilustración 45. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Naranja.

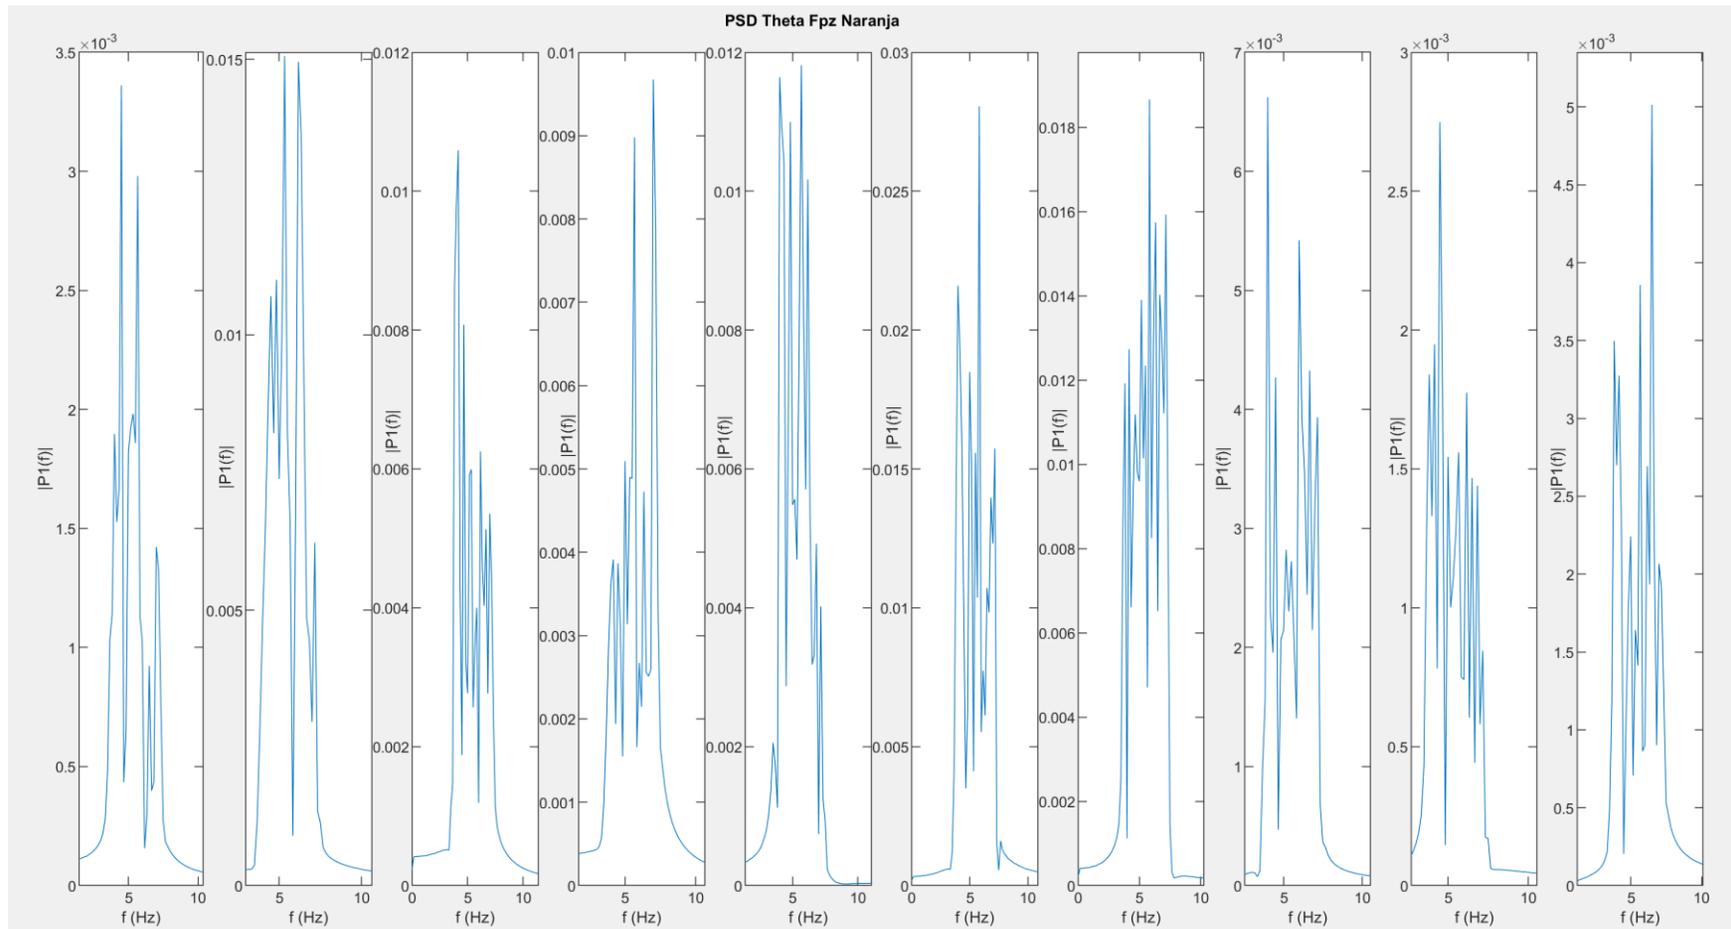


Ilustración 46. PSD Fpz correspondiente a 10 sujetos durante el OERP ritmo Theta de olfacción Naranja.

Medidas de tendencia central						
Medida estadística	Naranja Fp1		Naranja Fp2		Naranja Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Des. Estándar	0,554073724	0,004576789	1,158728392	0,008697332	1,014639126	0,007815637
Media	4,36376	0,010562711	4,96336	0,012223975	5,32978	0,011159544
Moda	4,16389	0,00696694	4,497	NA	4,497	NA
Moda	NA	NA	4,16389	NA	5,82945	NA

Tabla 15. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a naranja, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

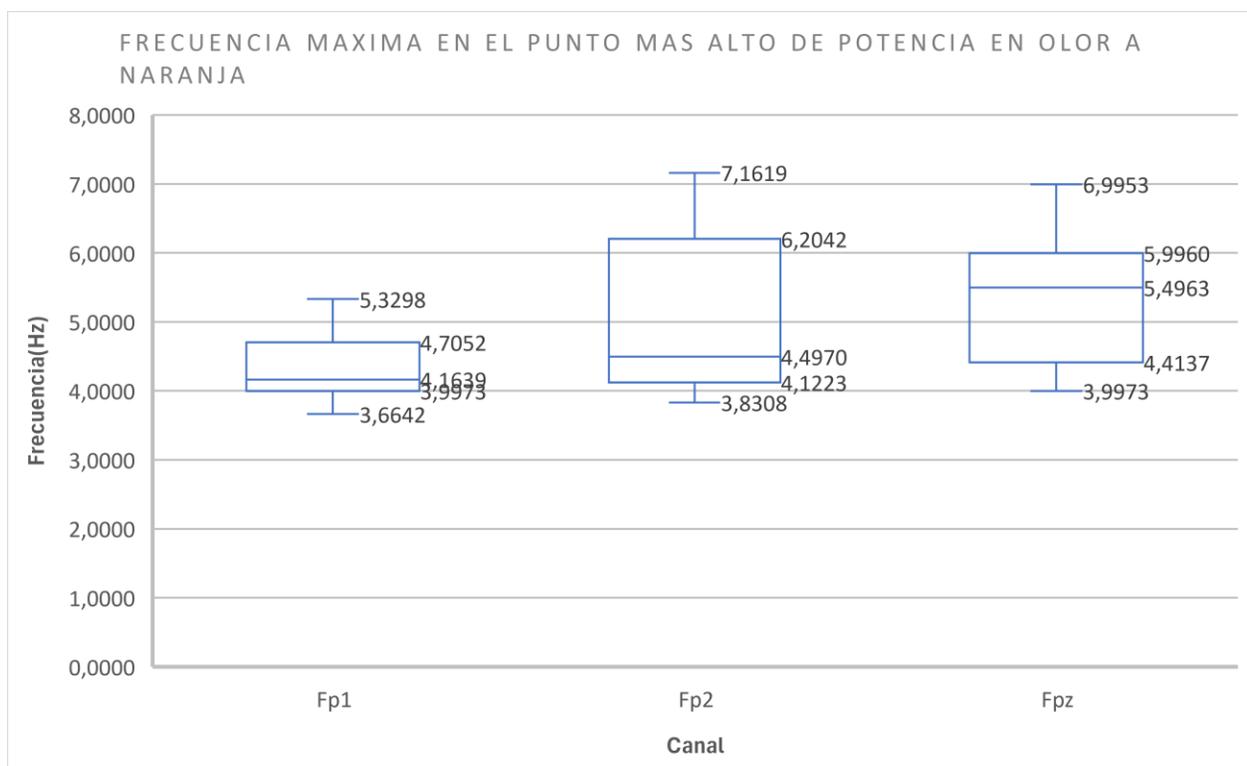


Ilustración 47. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Naranja.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Naranja, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp1 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 4,16389 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 4,36376 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,554073724 sugiriendo una homogeneidad en

la frecuencia dominante, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia identifica una moda de 0,00696694 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 0,010562711 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,004576789 sugiriendo una homogeneidad en la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Naranja, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp2 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal 4,497 y 4,16389 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 4,96336 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,158728392 sugiriendo que las frecuencias dominantes son relativamente homogéneos y se desvían en 1 unidad de la media, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, Se obtiene una media de 0,012223975 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,008697332 sugiriendo una homogeneidad en la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Naranja, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fpz la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal de 4,497 y 5,82945 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,32978 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,014639126 sugiriendo una relativa homogeneidad de la frecuencia dominante, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia no se identifica moda, se obtiene una media de 0,011159544 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,007815637 sugiriendo una homogeneidad de la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Atraves de la implementación de la FFT y posteriormente la representación del PSD de la señal se identificó que el pico de mayor densidad espectral para los 10 sujetos analizados en esta investigación se comportó entre los siguientes rangos:

Para la olfacción a Naranja, la frecuencia dominante en Fp1 [3,66422 5,32978]Hz, mientras tanto la densidad espectral de potencia en Fp1 [0,00454 0,01821] dBm/Hz.

la frecuencia dominante en Fp2 [3,83078 7,16189]Hz, mientras tanto la densidad espectral de potencia en Fp2 [0,00280 0,03350] dBm/Hz.

la frecuencia dominante en Fpz [3,99734 6,99534]Hz, mientras tanto la densidad espectral de potencia en Fpz [0,00275 0,02805] dBm/Hz.

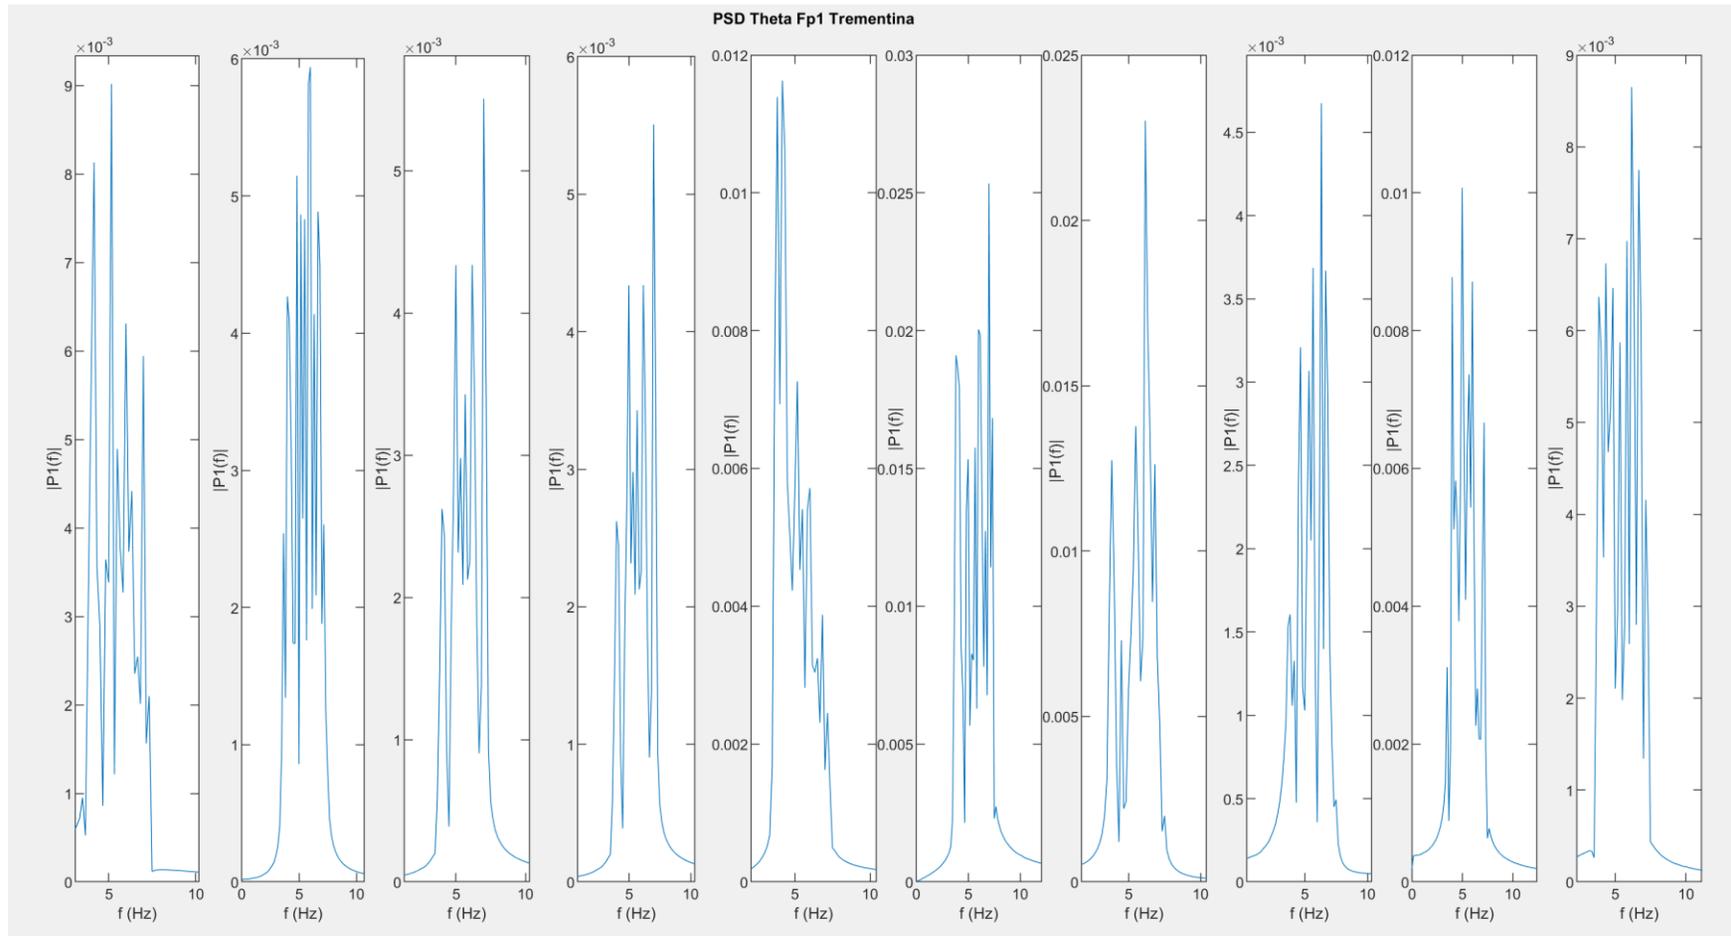


Ilustración 48. PSD Fp1 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Trementina.

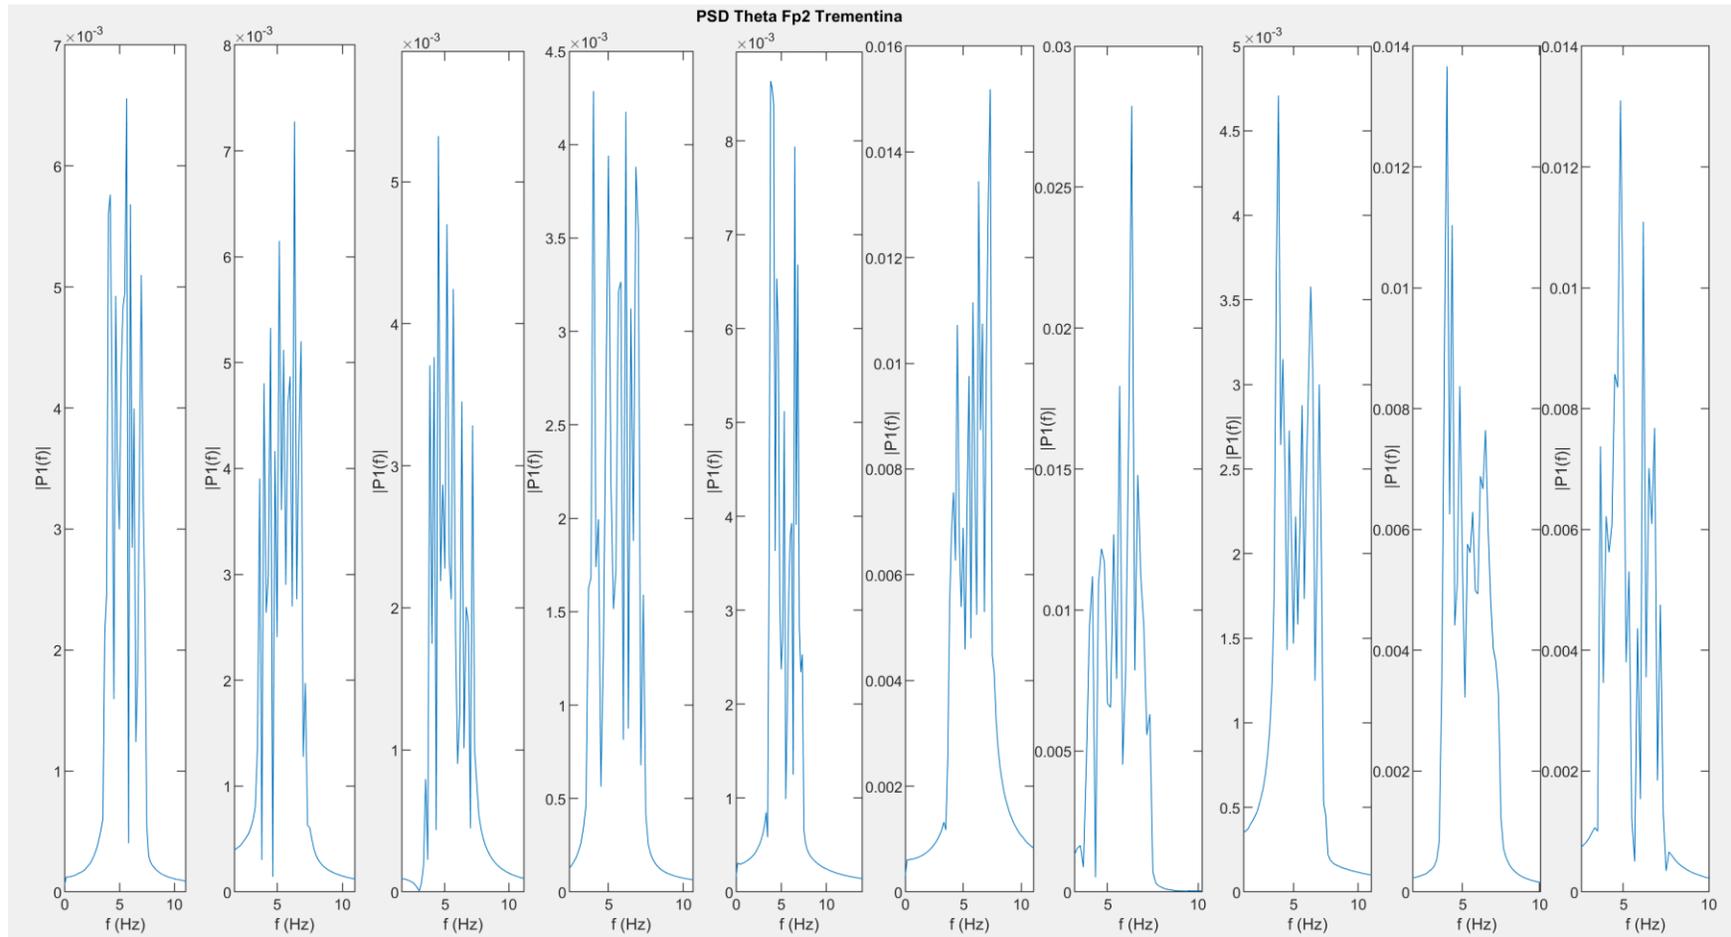


Ilustración 49. PSD Fp2 correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Trementina.

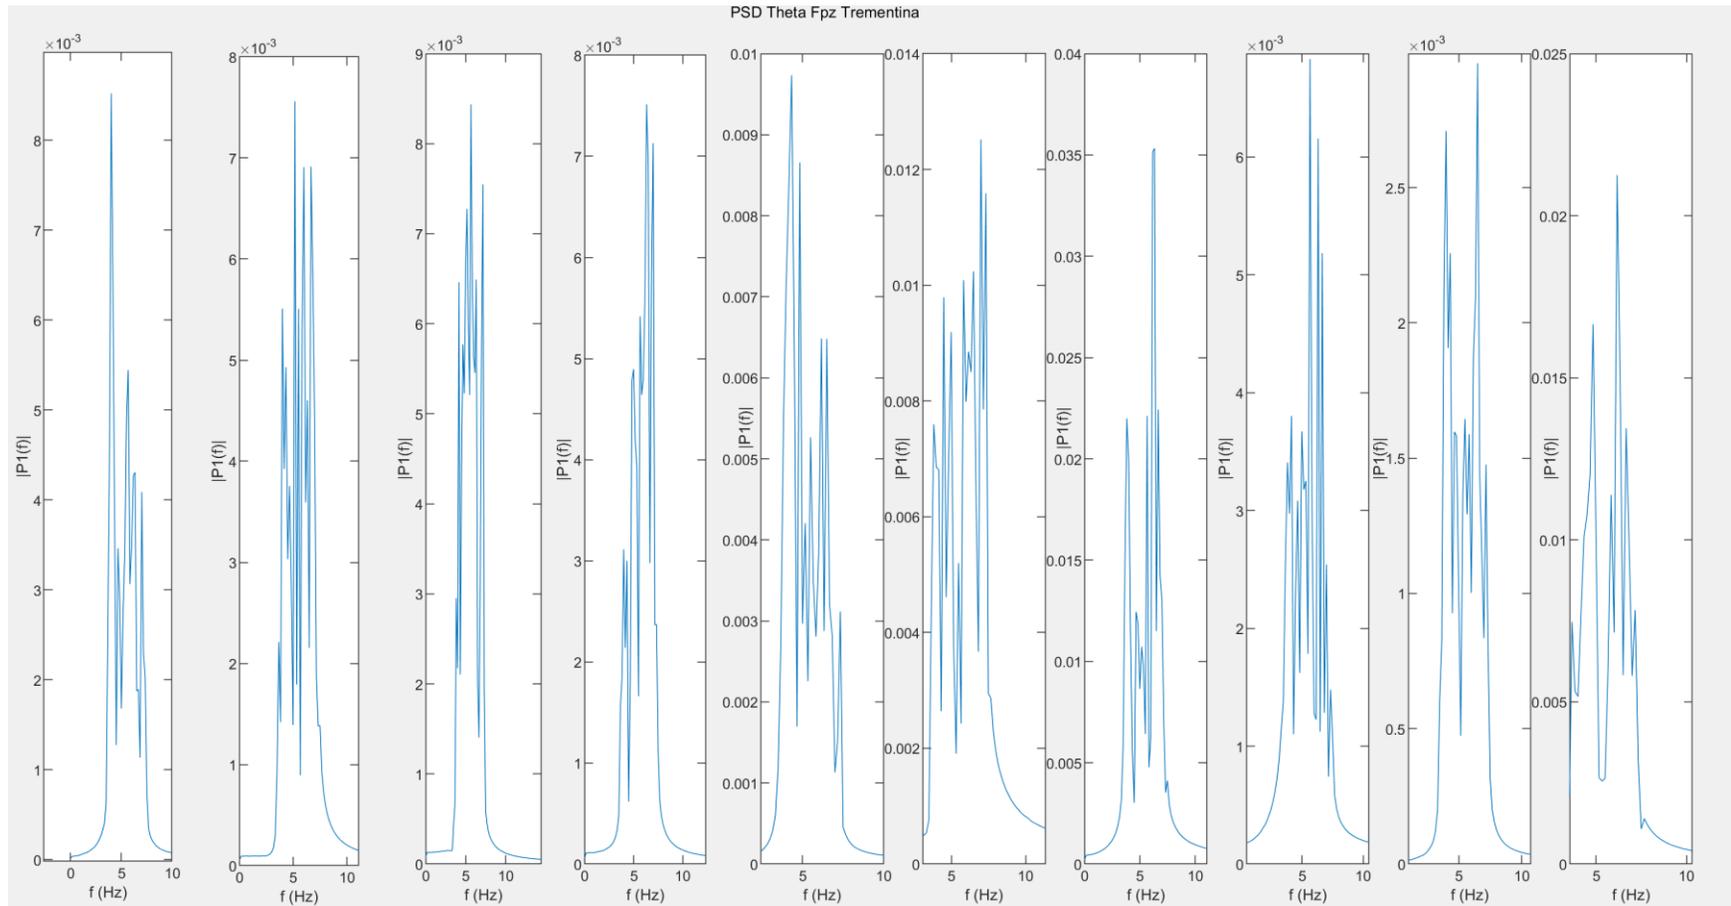


Ilustración 50. PSD Fpz correspondiente a 10 sujetos durante el OERP del ritmo Theta de olfacción Trentina.

Medidas de tendencia central						
Medida estadística	Trementina Fp1		Trementina Fp2		Trementina Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Des. Estándar	0,955178754	0,007353528	1,264066999	0,007217961	0,964967994	0,009474915
Media	5,99600	0,010935592	5,06329	0,010662749	5,71286	0,012065318
Moda	6,99534	0,00550728	6,32911	0,010662749	5,66289	0,012065318
Moda	NA	NA	3,99734	NA	6,32911	NA
Moda	NA	NA	3,83078	NA	NA	NA

Tabla 16. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a Trementina, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

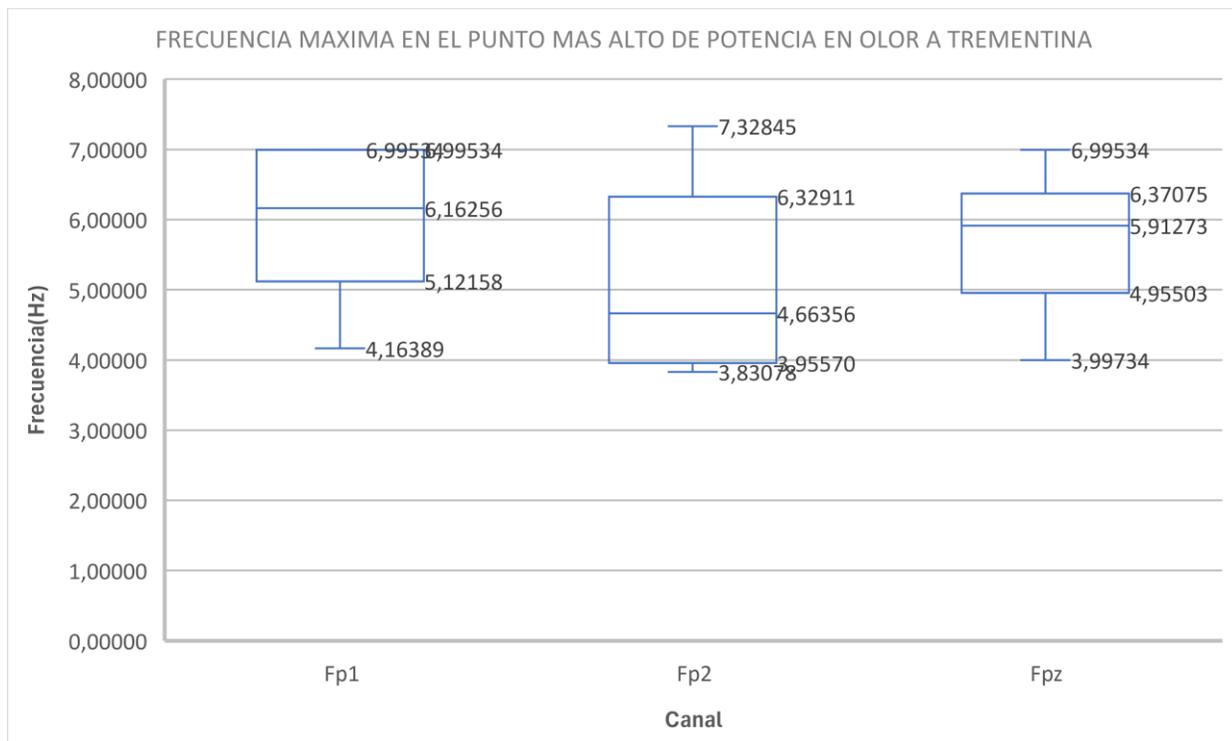


Ilustración 51. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1, Fp2 y Fpz en el olor a Trementina.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Trementina, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp1 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica una moda de 6,99534 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,99600 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,955178754 sugiriendo una

homogeneidad de frecuencia dominante, poca variabilidad y cercanía a la media. Así mismo en la densidad espectral de potencia identifica una moda de 0,00550728 dBm/Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 0,010935592 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,007353528 sugiriendo una homogeneidad en la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Trementina, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fp2 la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica trimodal de 3,99734, 3,83078 y 6,32911 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,06329 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 1,264066999 sugiriendo las frecuencias dominantes son relativamente homogéneos y se desvían en 1 unidad de la media, poca variabilidad de los datos y cercanía a la media. Así mismo en la densidad espectral de potencia se identifica una moda de 0,010662749 dBm/Hz, Se obtiene una media de 0,010662749 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,007217961 sugiriendo una homogeneidad en la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Las medidas de tendencia central de OERP del ritmo Theta para la olfacción a Trementina, tomando como referencia el punto máximo de la densidad espectral en la frecuencia dominante se identifica que para Fpz la frecuencia dominante para los datos provenientes de los 10 sujetos analizados en esta investigación se identifica bimodal de 5,66289 y 6,32911 Hz denotando una repetitividad en varios sujetos, Se obtiene una media de 5,71286 Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,964967994 sugiriendo homogeneidad en la frecuencia dominante, poca variabilidad y cercanía a la media. Así mismo en la densidad espectral de potencia se identifica una moda de 0,01265318 dBm/Hz, se obtiene una media de 0,01265318 dBm/Hz denotando el promedio de la frecuencia en la que se comportan los datos y una desviación estándar de 0,01265318 sugiriendo una homogeneidad en la densidad espectral de potencia, poca variabilidad y cercanía a la media.

Atreves de la implementación de la FFT y posteriormente la representación del PSD de la señal se

identificó que el pico de mayor densidad espectral para los 10 sujetos analizados en esta investigación se comportó entre los siguientes rangos:

Para la olfacción a Trementina, la frecuencia dominante en Fp1 [4,16389 6,99534]Hz, mientras tanto la densidad espectral de potencia en Fp1[0,00467401 0,0253417] dBm/Hz.

la frecuencia dominante en Fp2 [3,83078 7,32845]Hz, mientras tanto la densidad espectral de potencia en Fp2 [0,00428605 0,0278797] dBm/Hz.

la frecuencia dominante en Fpz [3,99734 6,99534]Hz, mientras tanto la densidad espectral de potencia en Fpz [0,00295975 0,0353226] dBm/Hz.

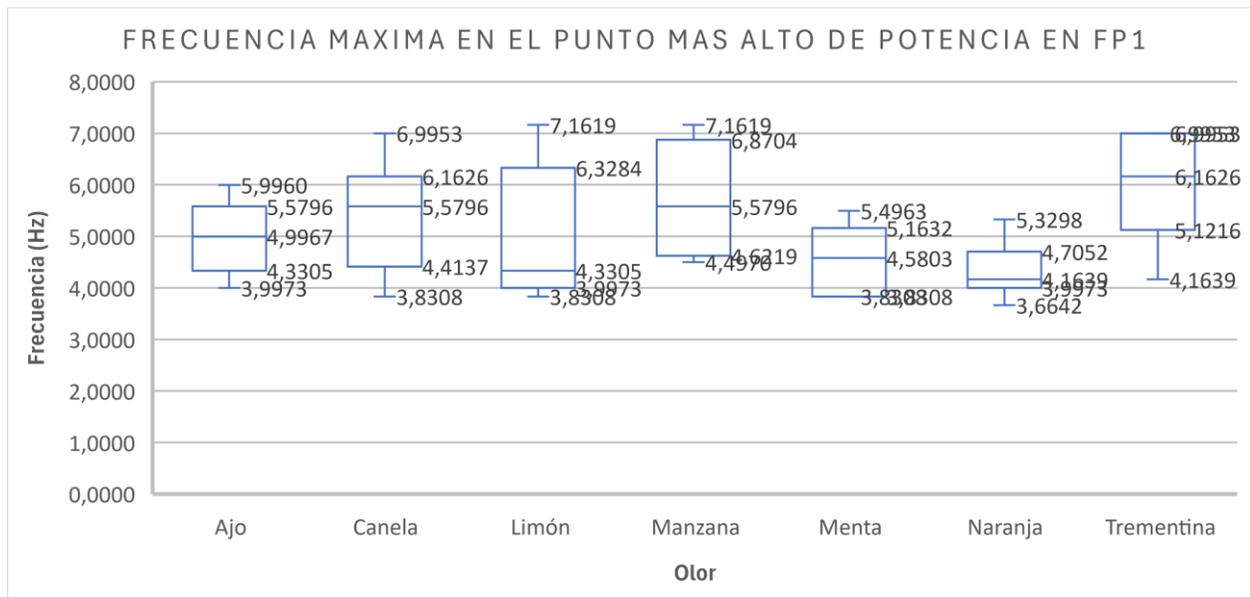


Ilustración 52. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp1 en el olor a Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.

La frecuencia mínima con mayor repetitividad que se hayo el punto más alto de densidad espectral de ponencia para Fp1 es de 3,83078 Hz en lo olores a Canela, Limón y Menta.

La frecuencia máxima con mayor repetitividad que se hayo el punto más alto de densidad espectral de ponencia para Fp1 es de 7,16189Hz en lo olores a Limón y Manzana.

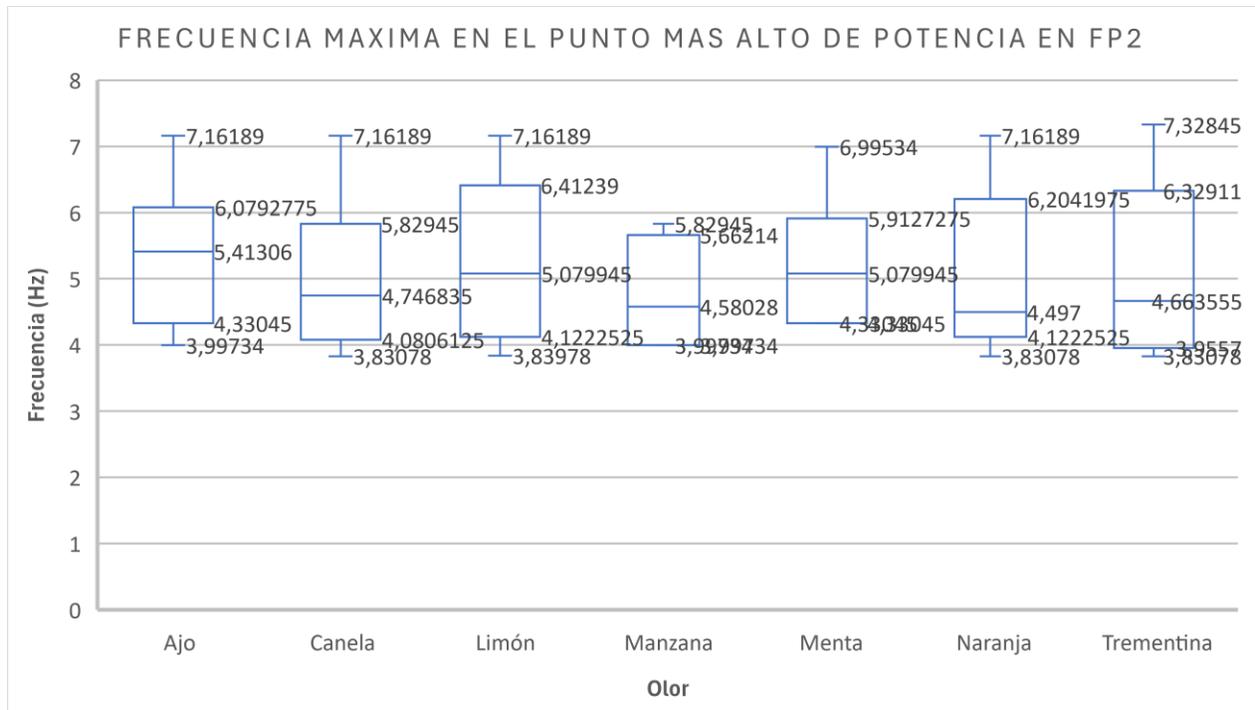


Ilustración 53. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fp2 en el olor a Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.

La frecuencia mínima con mayor repetitividad que se hayo el punto más alto de densidad espectral de ponencia para Fp2 es de 3,83078 Hz en lo olores a Canela, Naranja y Trementina.

La frecuencia máxima con mayor repetitividad que se hayo el punto más alto de densidad espectral de ponencia para Fp2 es de 7,16189 Hz en lo olores a Naranja, Limón, Canela, Ajo.

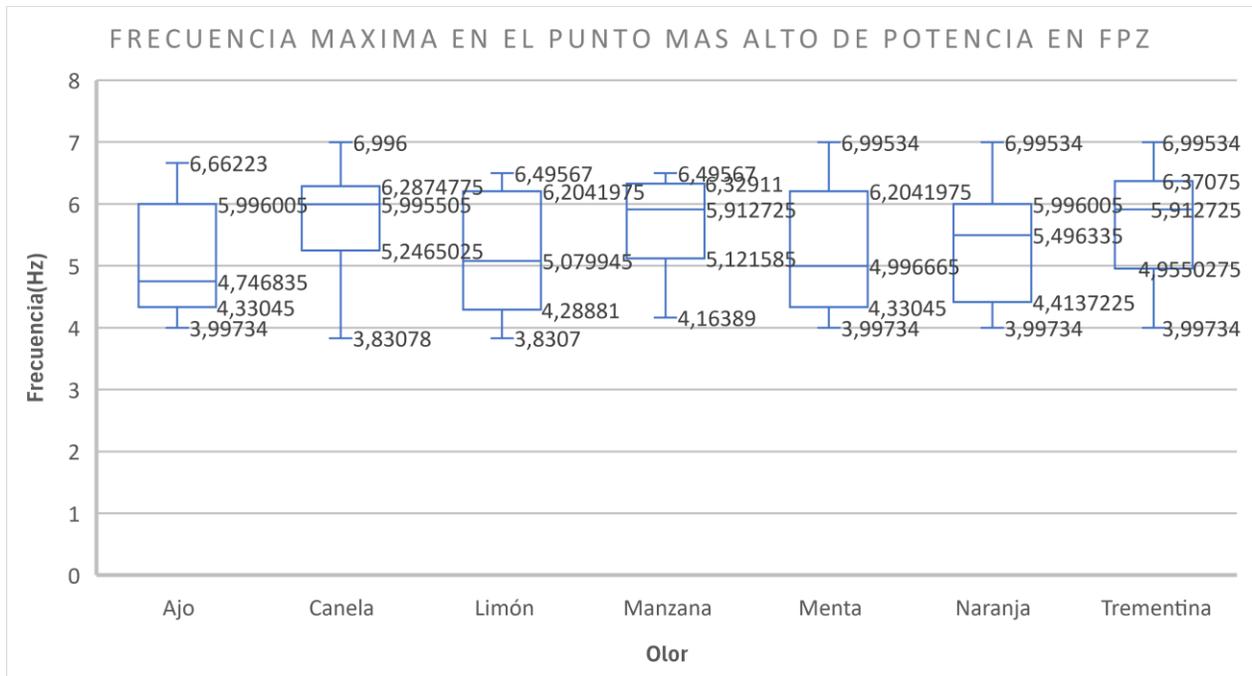


Ilustración 54. Diagrama de cajas y bigotes de la frecuencia máxima en el punto más alto de potencia para Fpz en el olor a Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.

La frecuencia máxima con mayor repetitividad que se hayo el punto más alto de densidad espectral de ponencia para Fpz es de 6,99534 Hz en lo olores a Menta, Naranja y Trementina.

La frecuencia mínima con mayor repetitividad que se hayo el punto más alto de densidad espectral de ponencia para Fpz es de 3,99734 Hz en lo olores a Ajo, Menta, Naranja y Trementina.



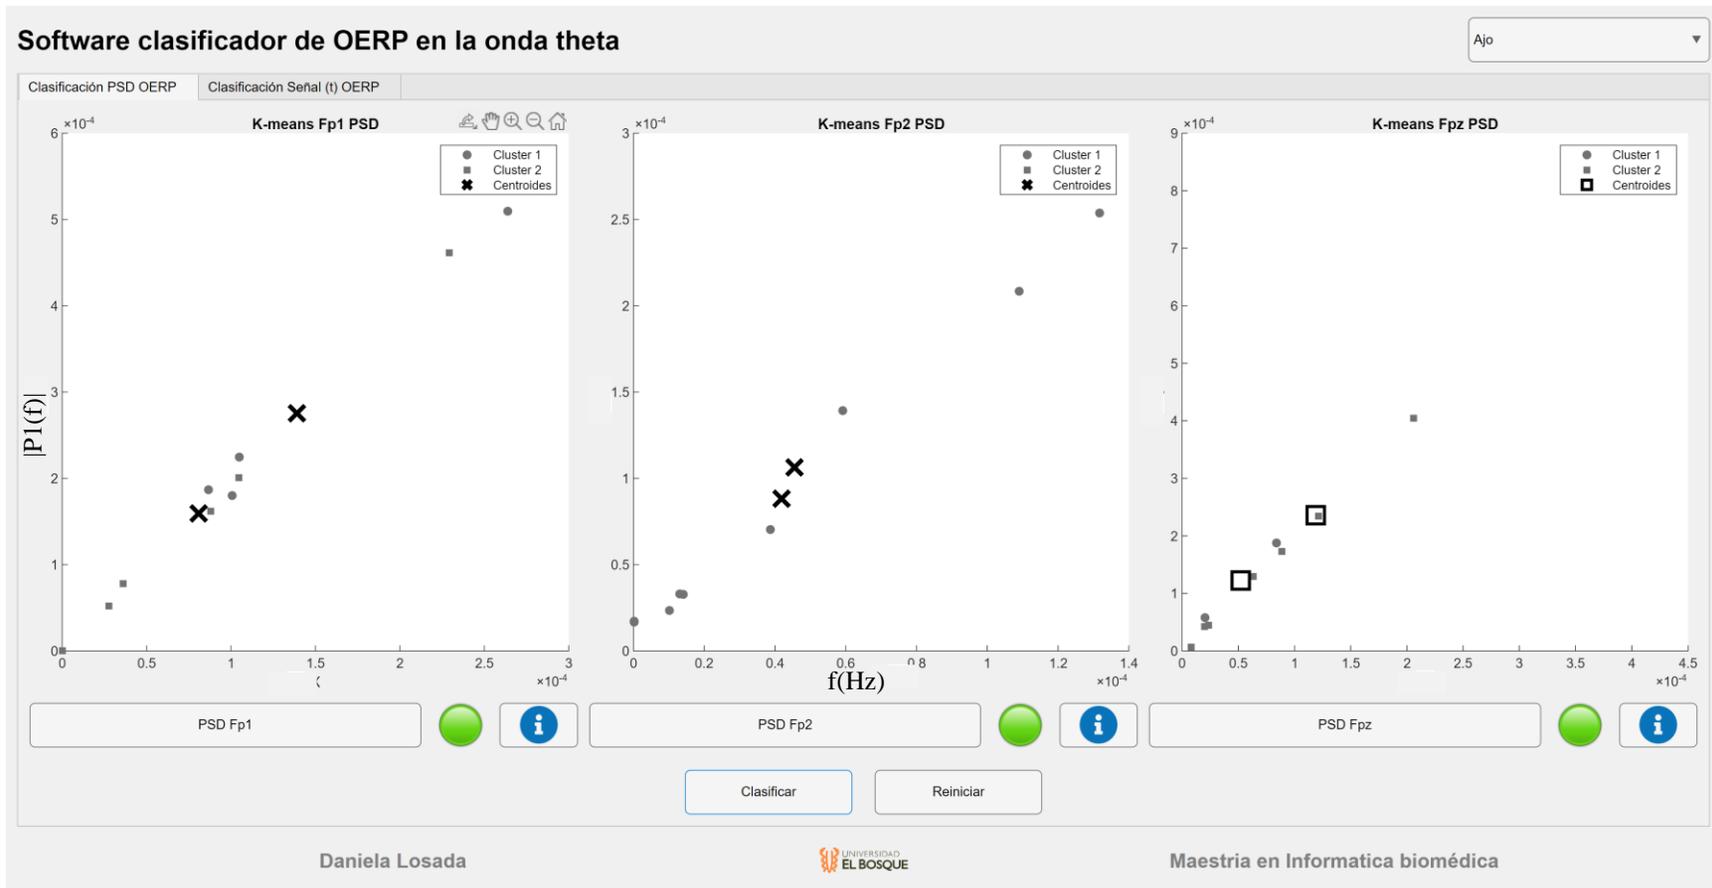


Ilustración 55. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Ajo.

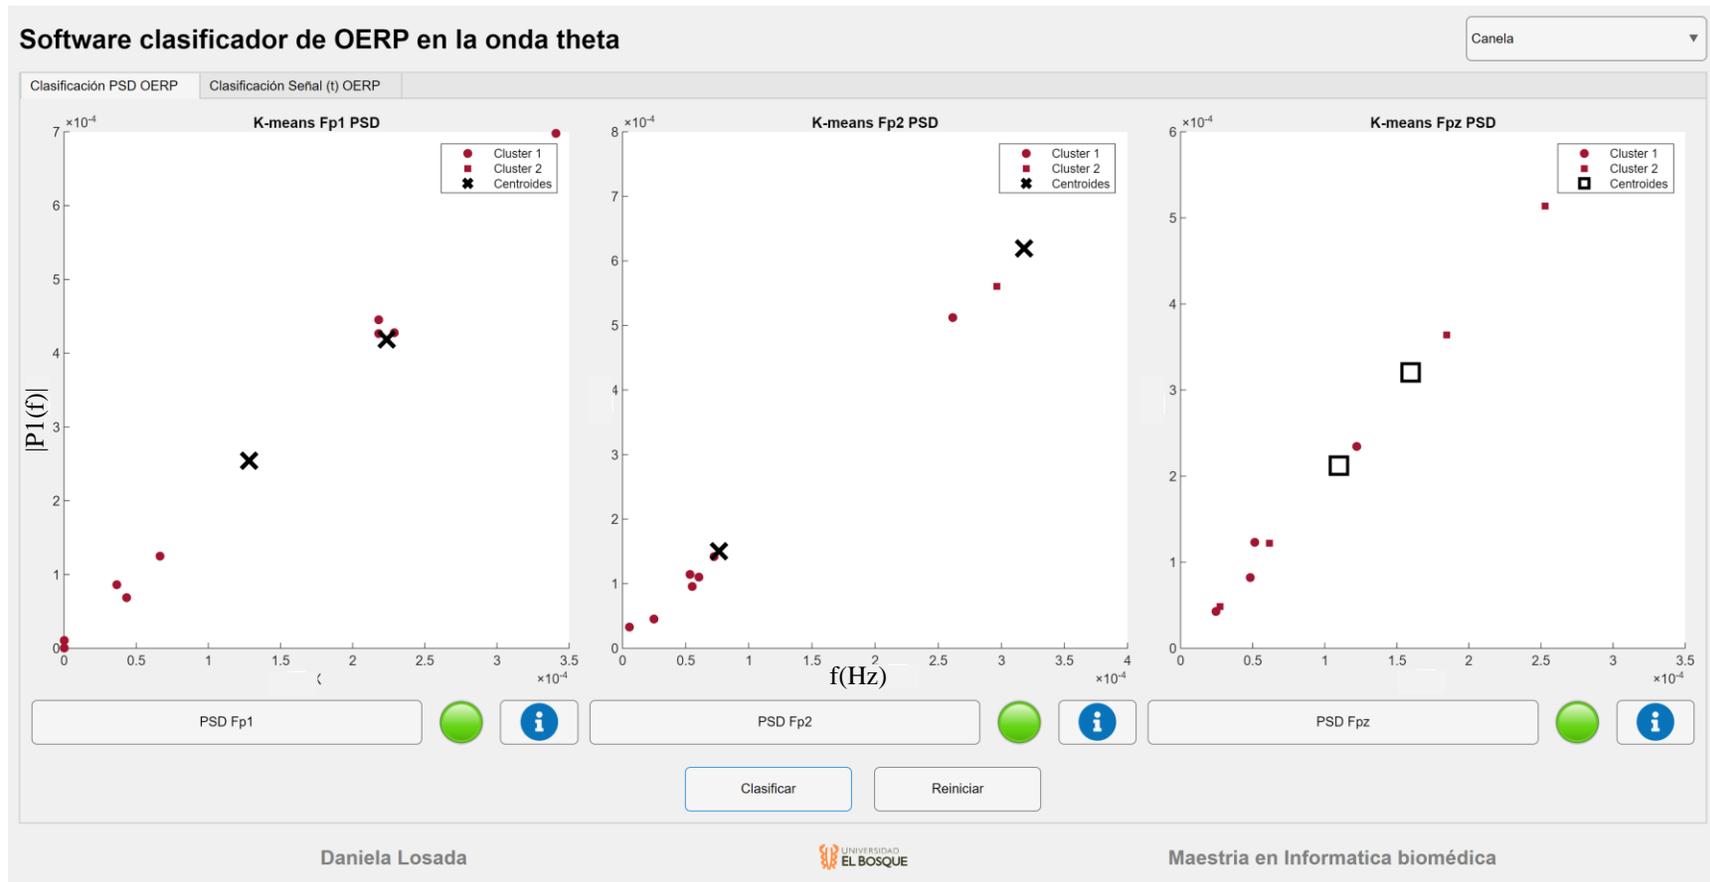


Ilustración 56. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Canela.

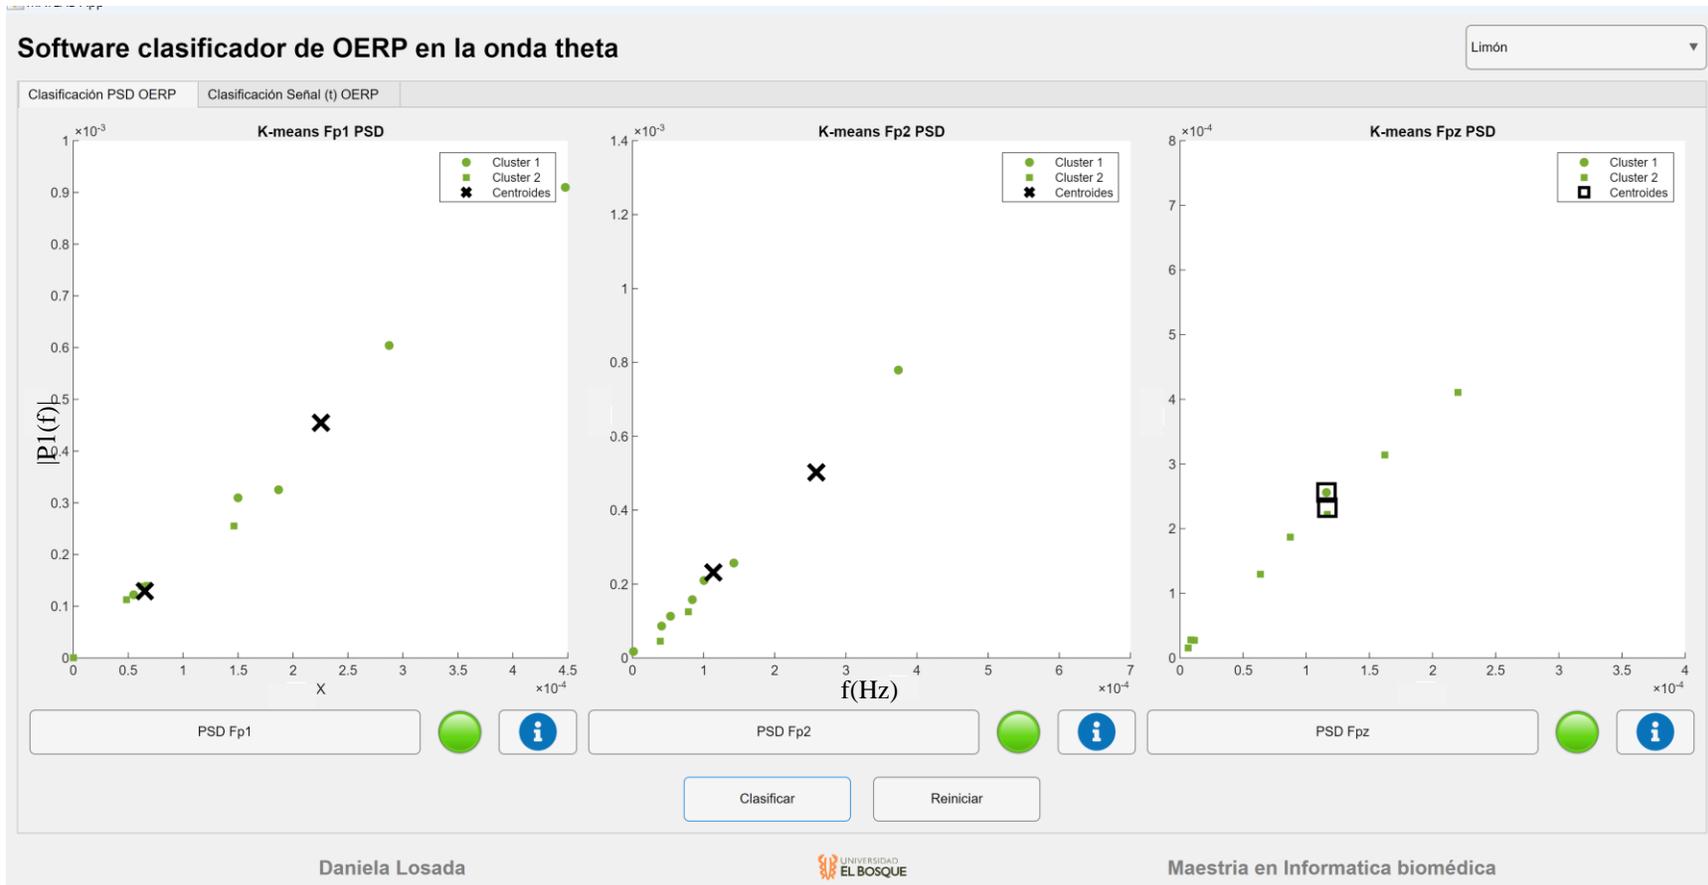


Ilustración 57. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Limón.

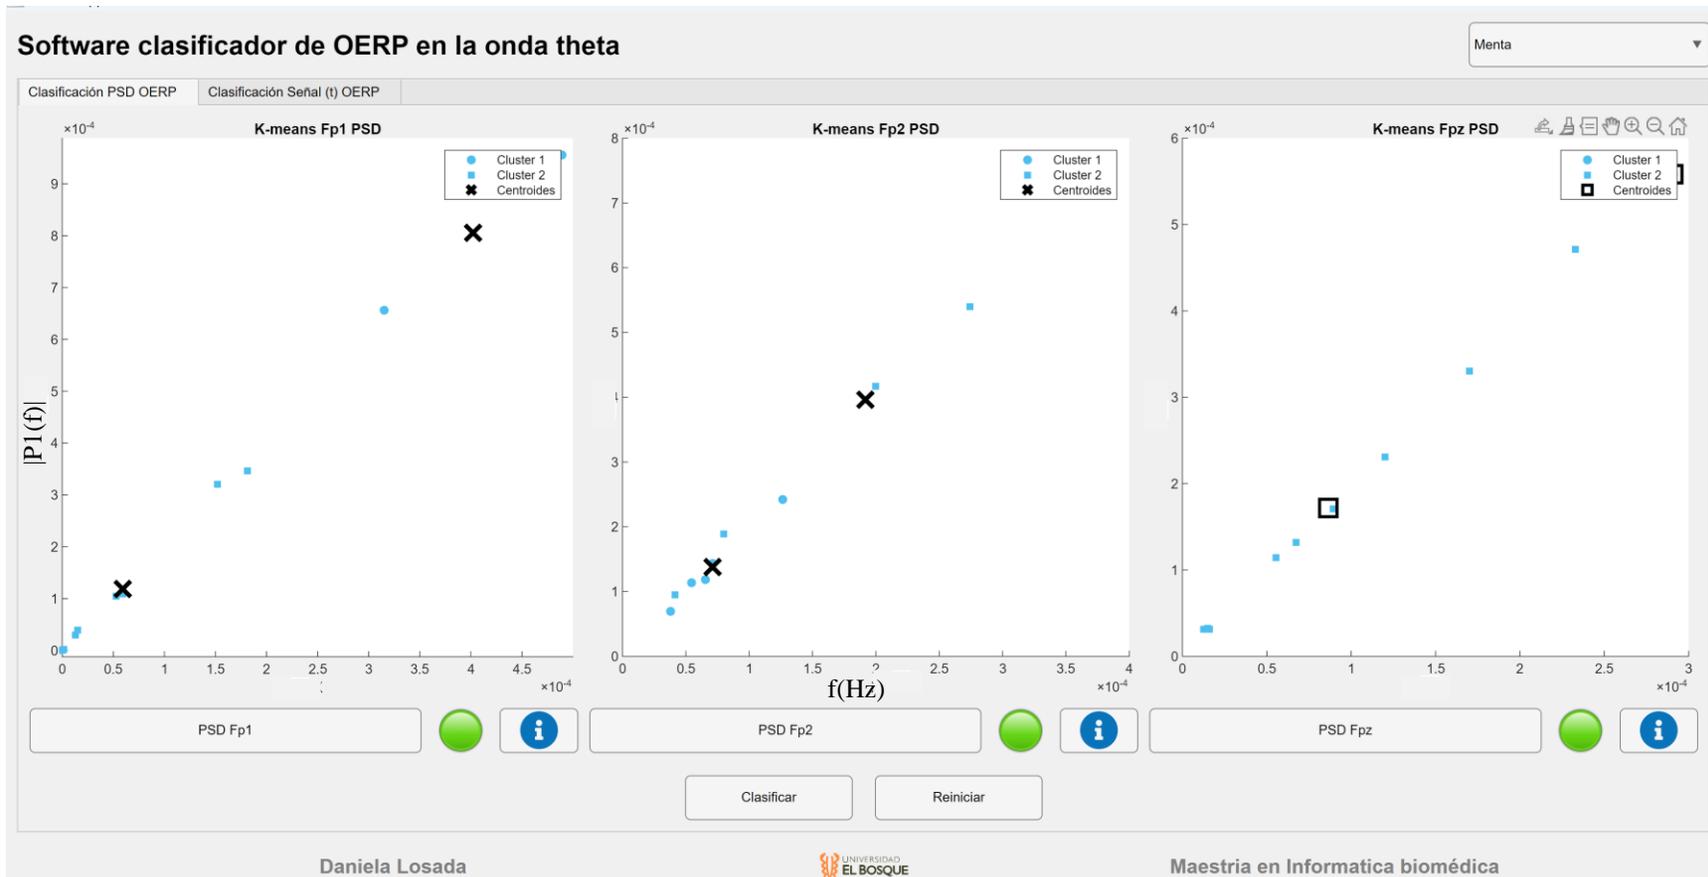


Ilustración 58. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Menta.

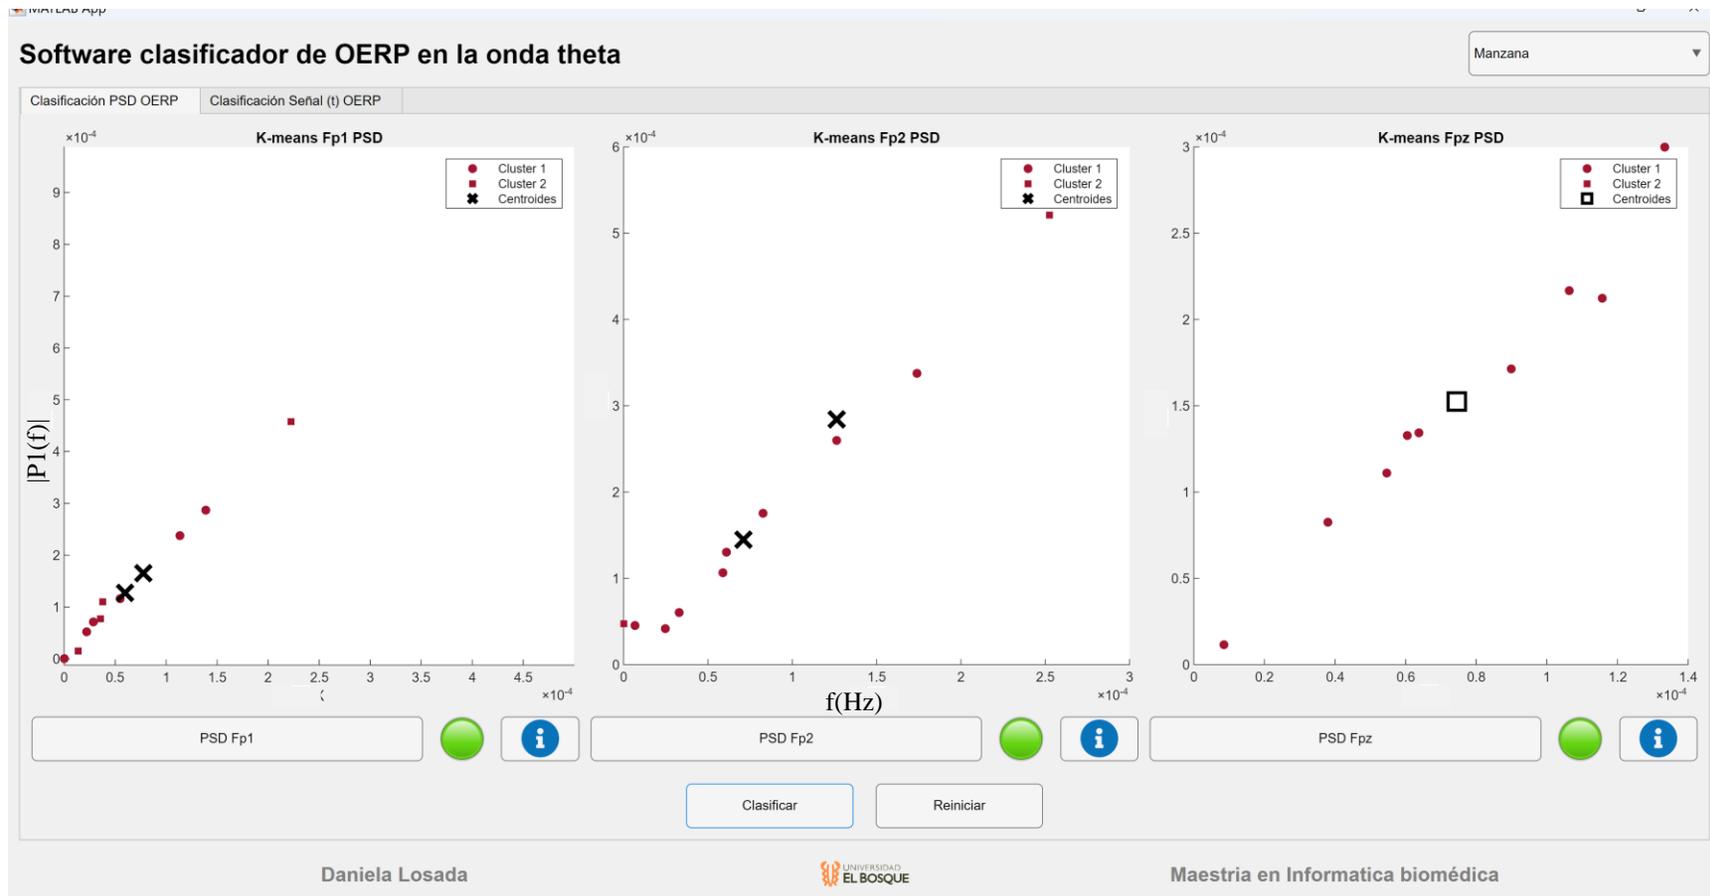


Ilustración 59. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Manzana.

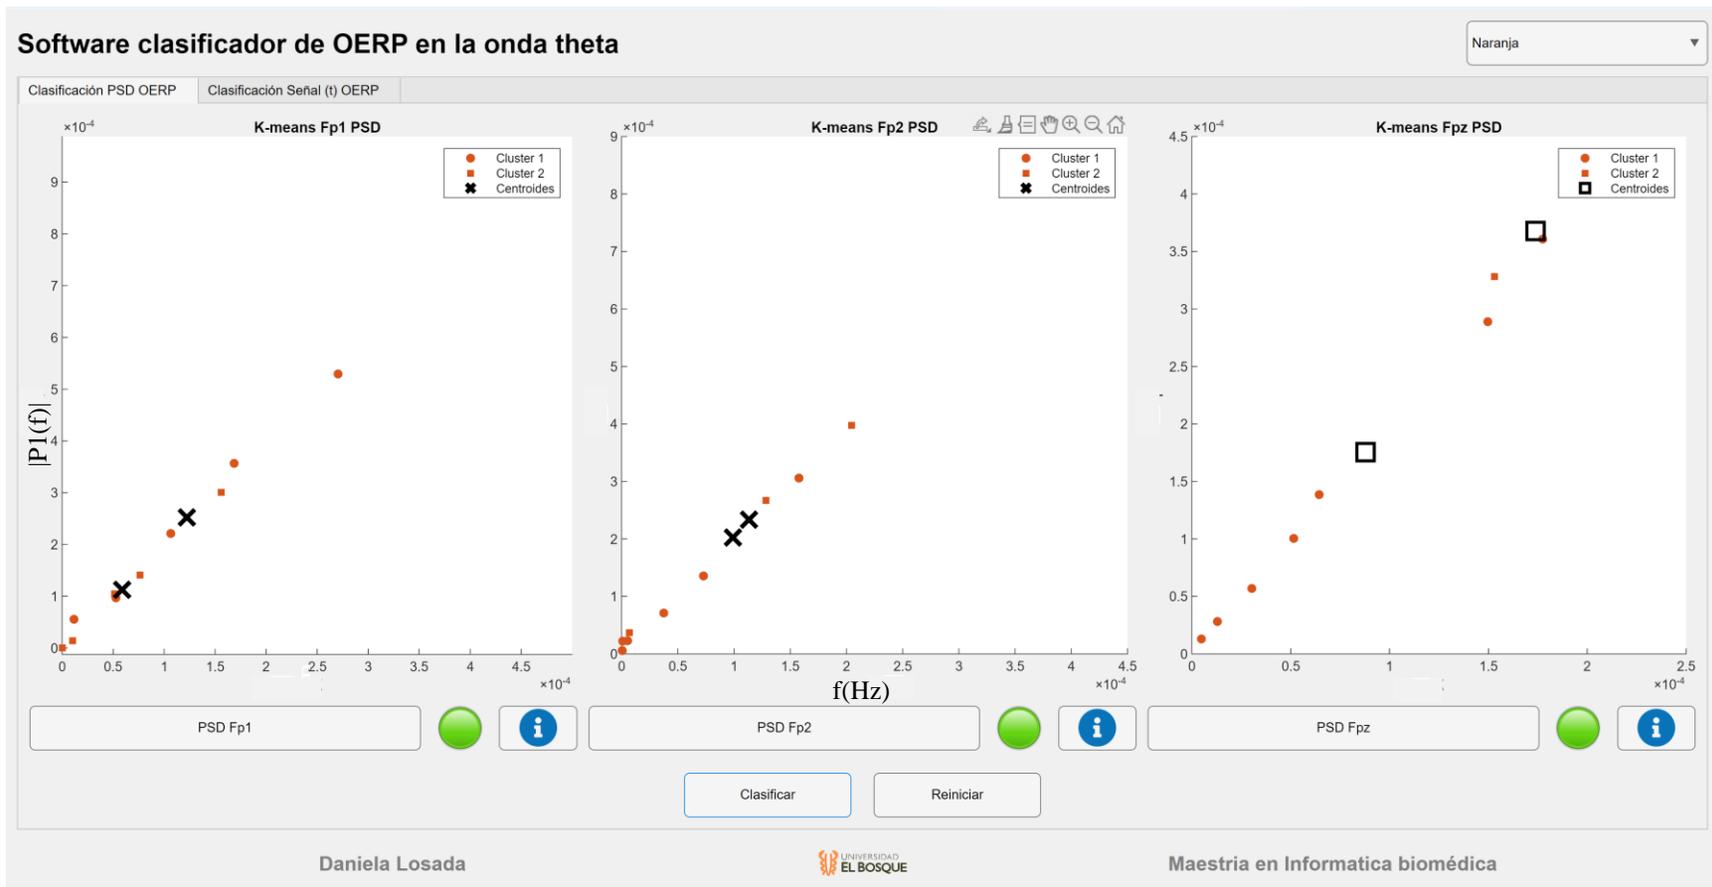


Ilustración 60. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Naranja.

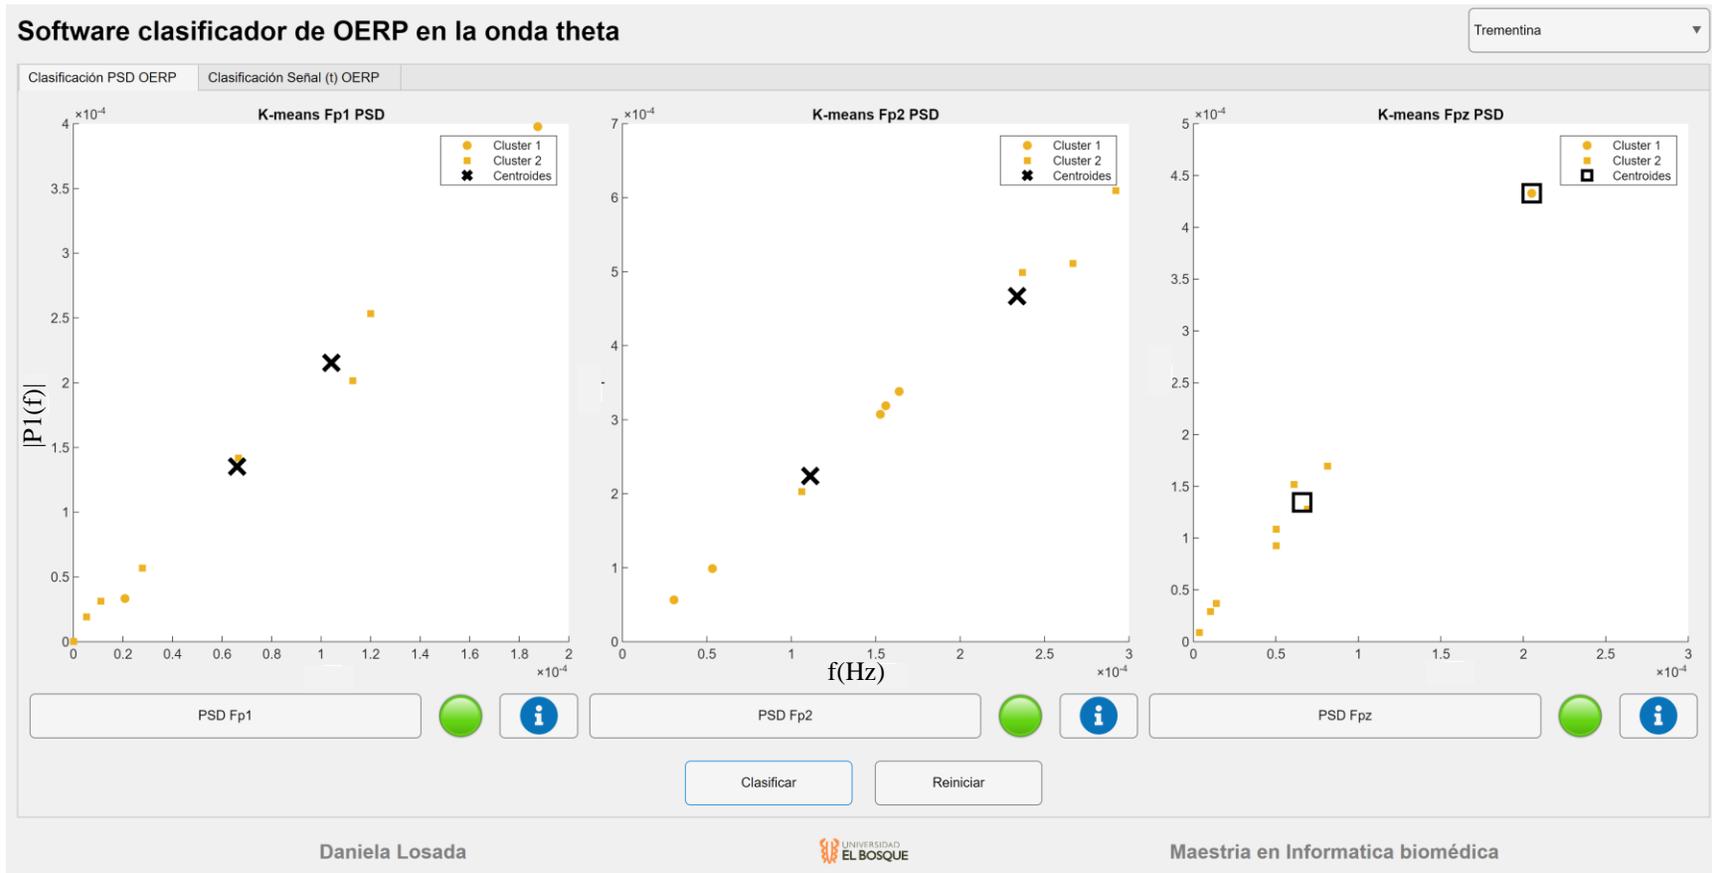


Ilustración 61. K-means correspondiente de la señal resultante del procesamiento del PSD de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Trementina.

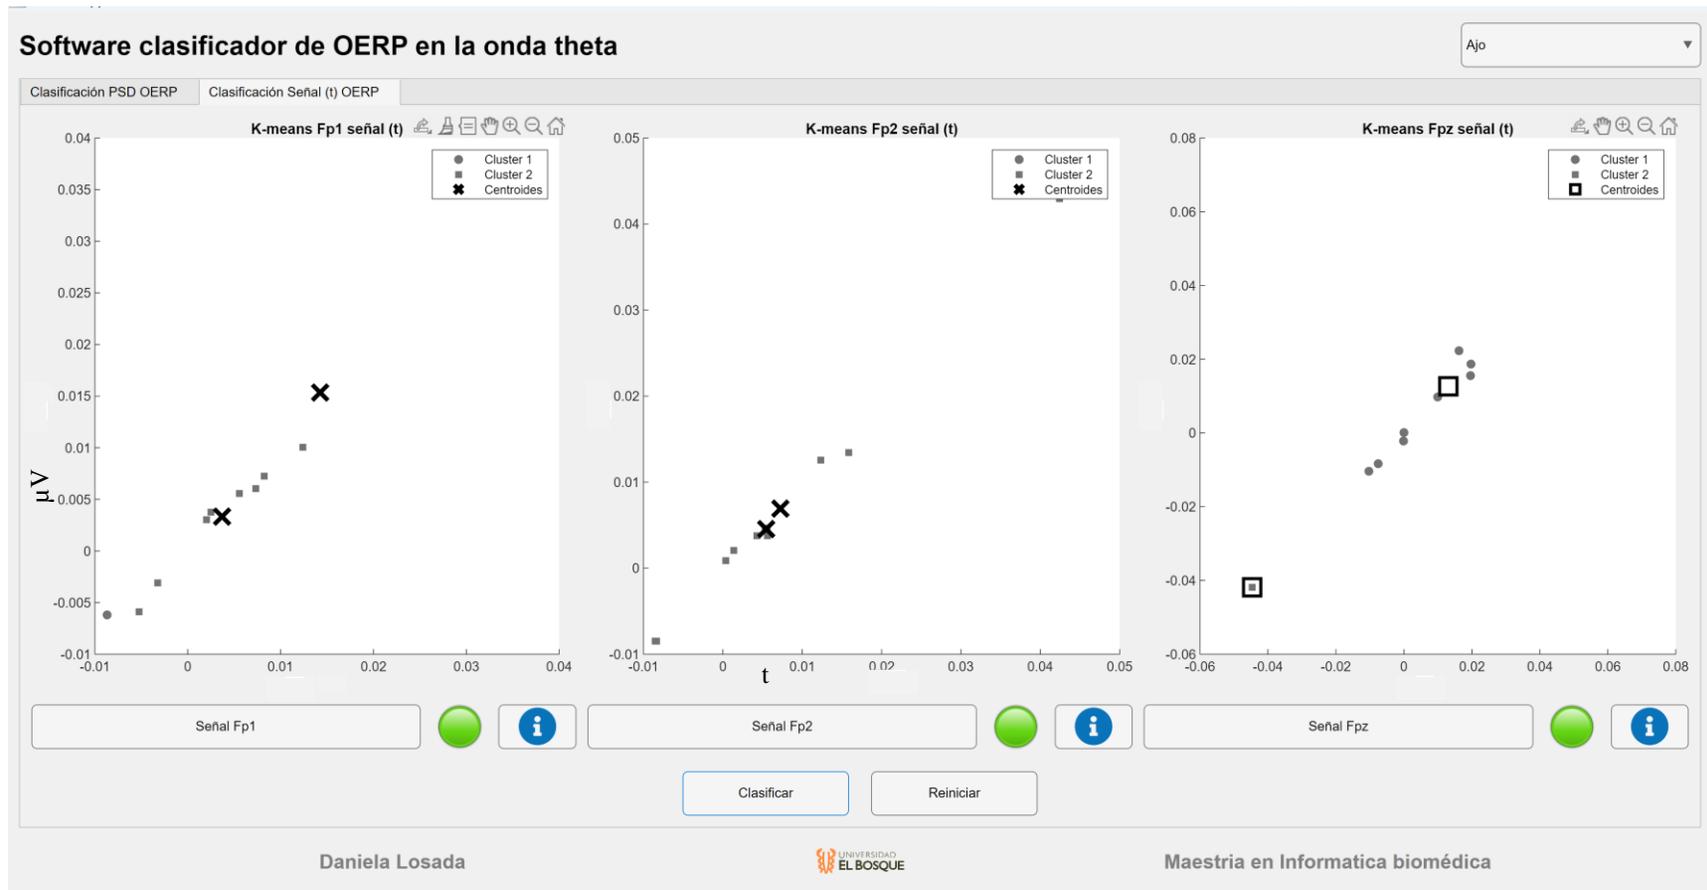


Ilustración 62. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Ajo.

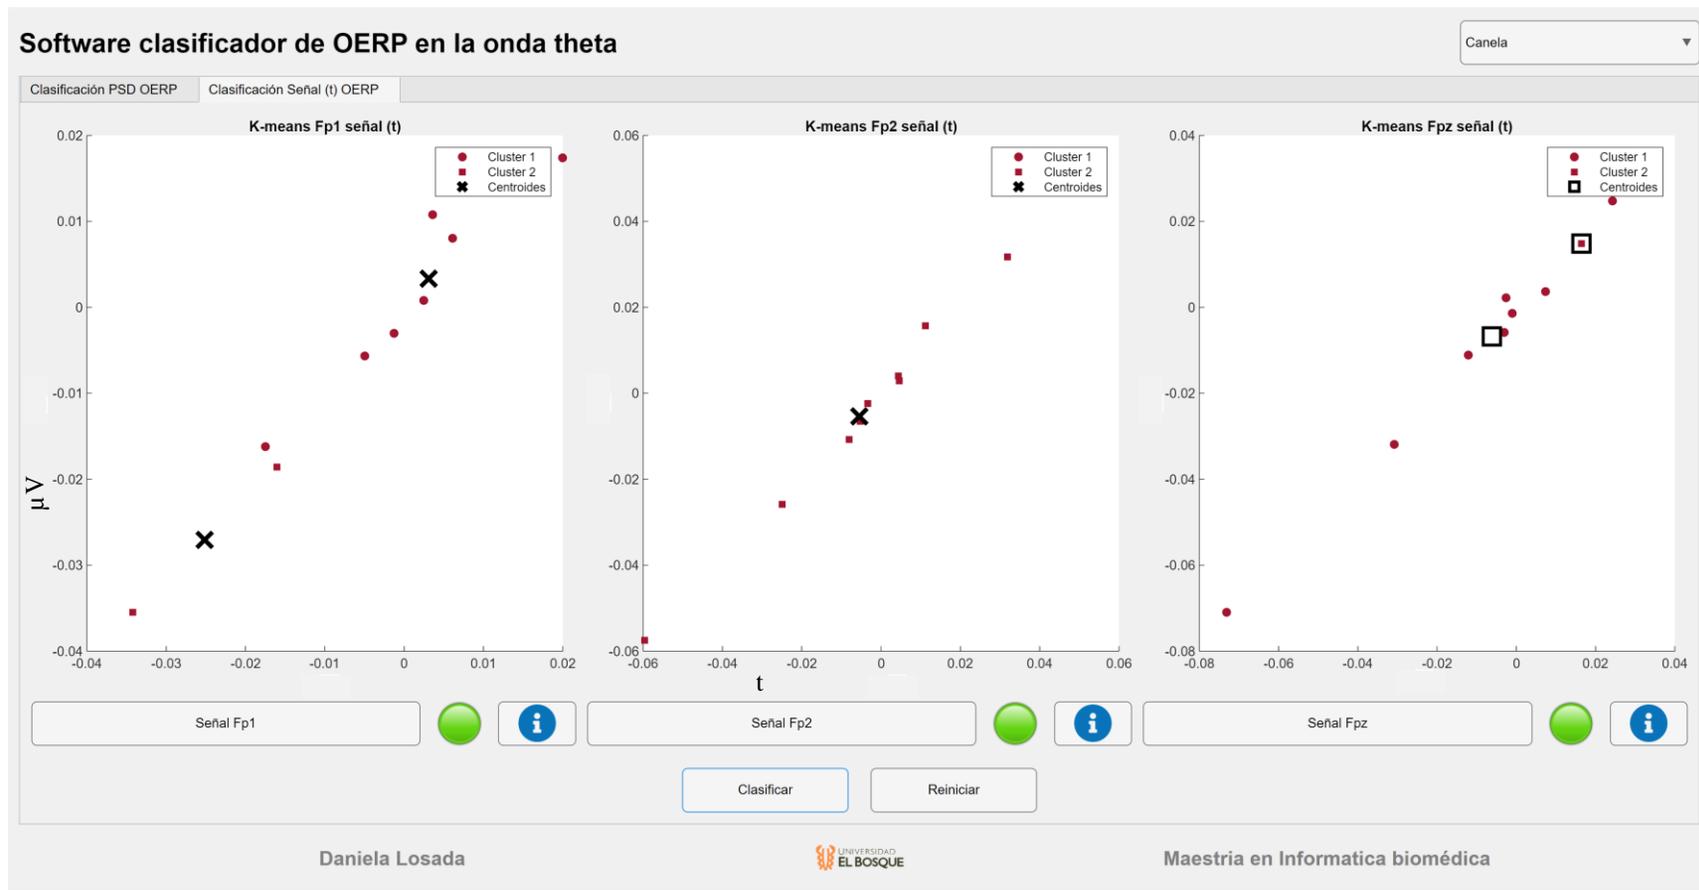


Ilustración 63. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Canela.

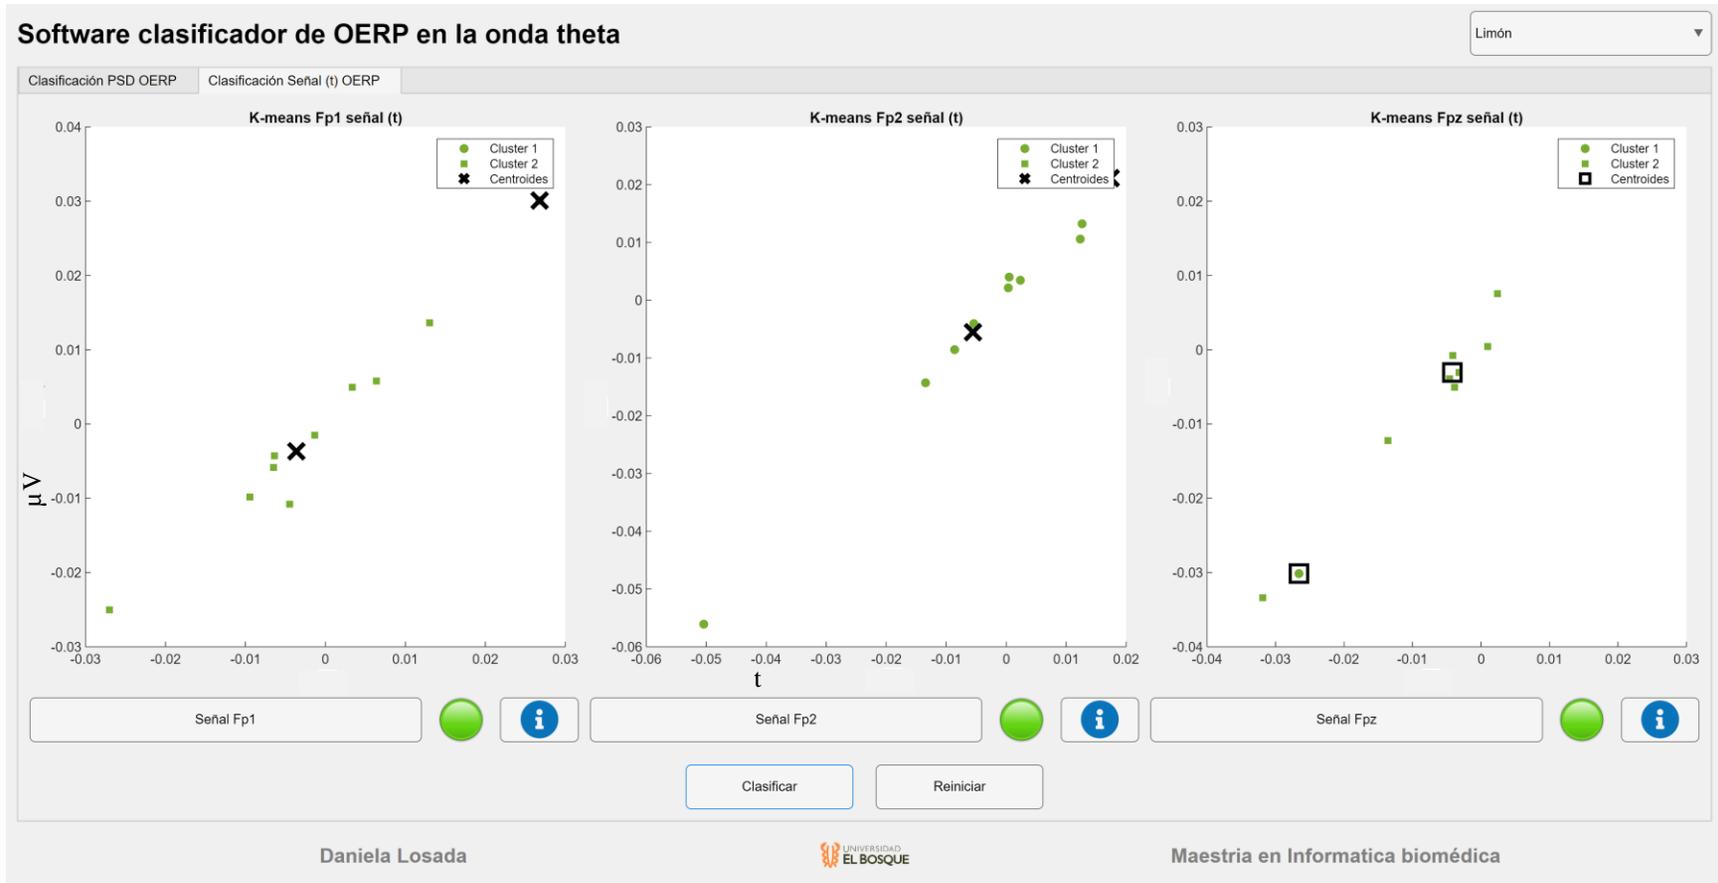


Ilustración 64. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Limón.

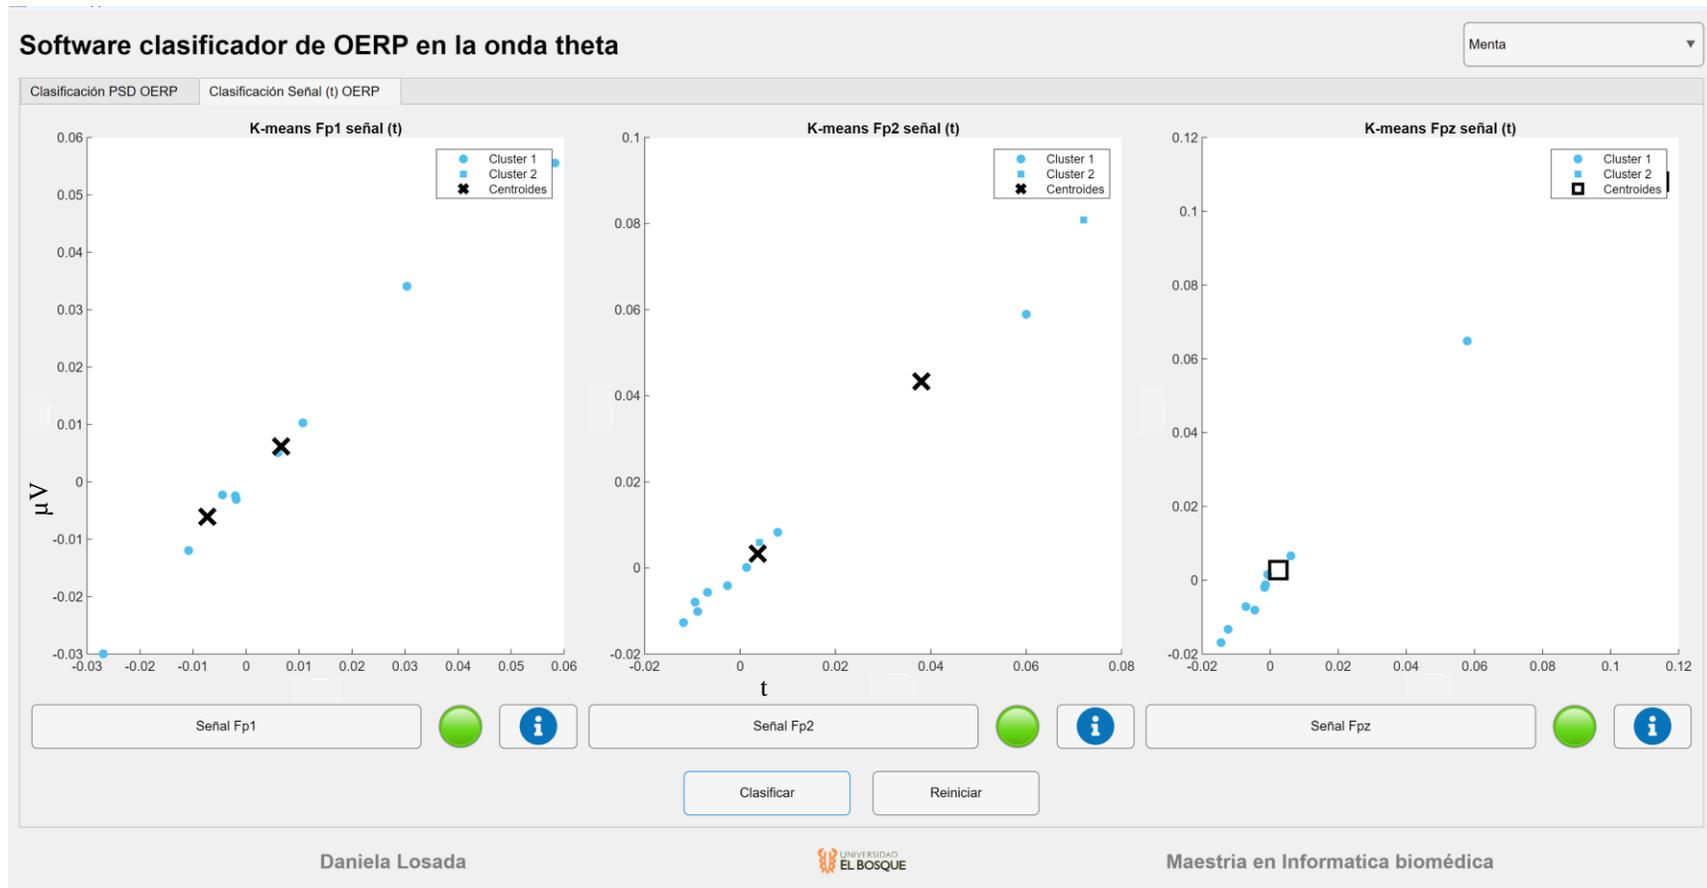


Ilustración 65. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Menta.

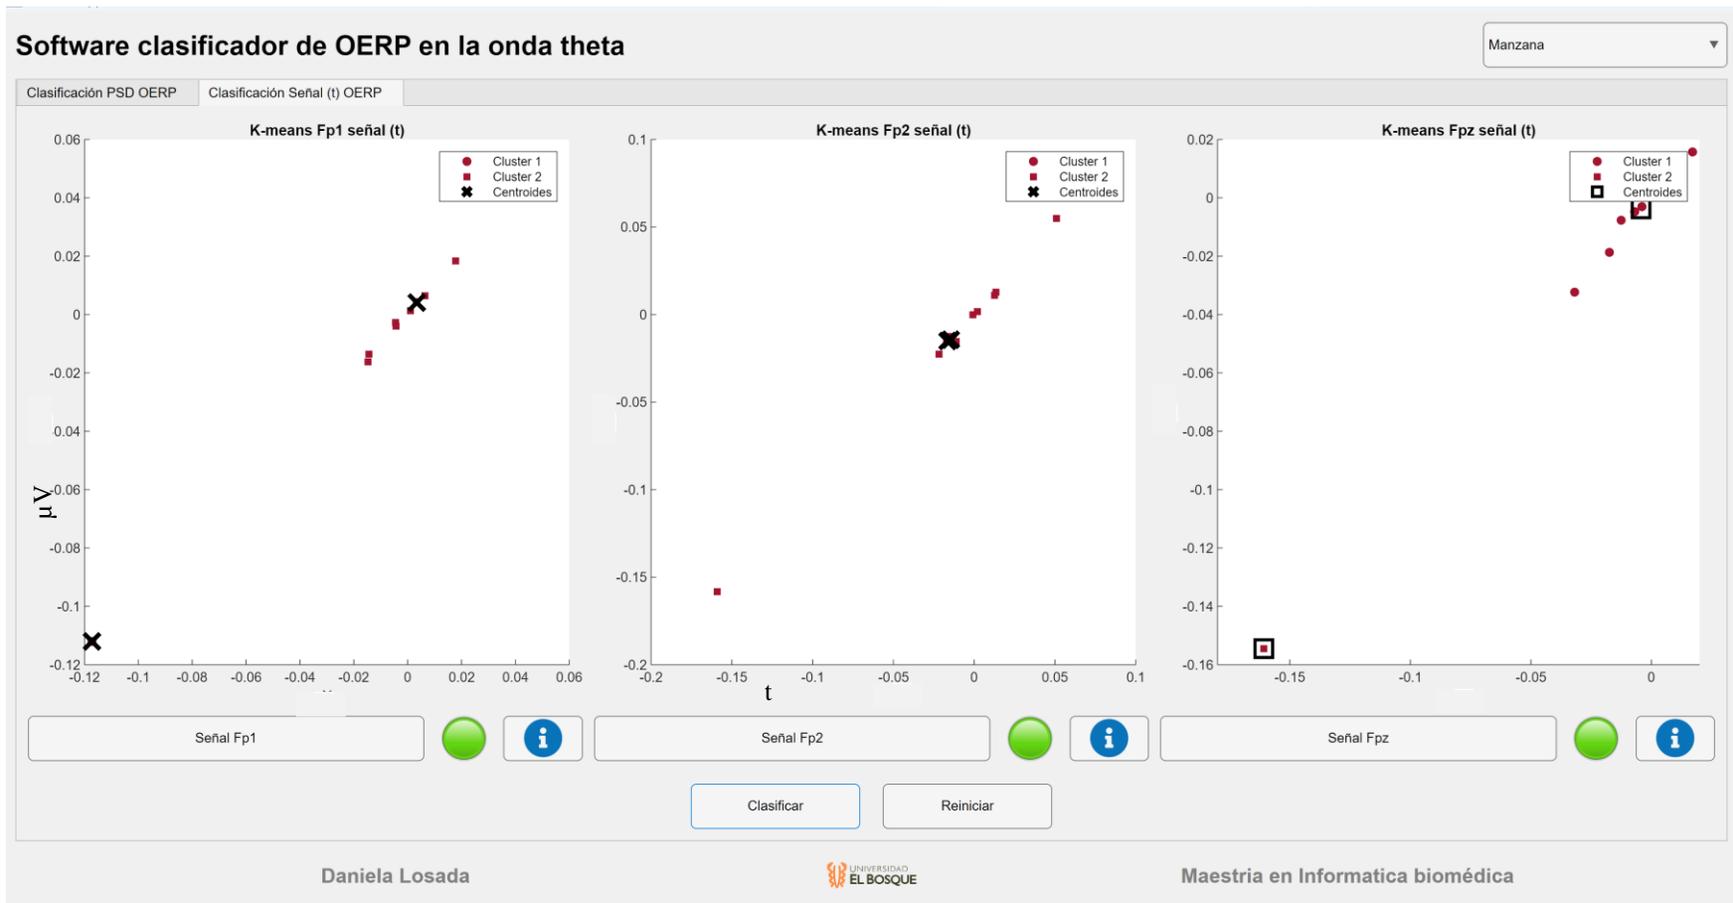


Ilustración 66. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Manzana.

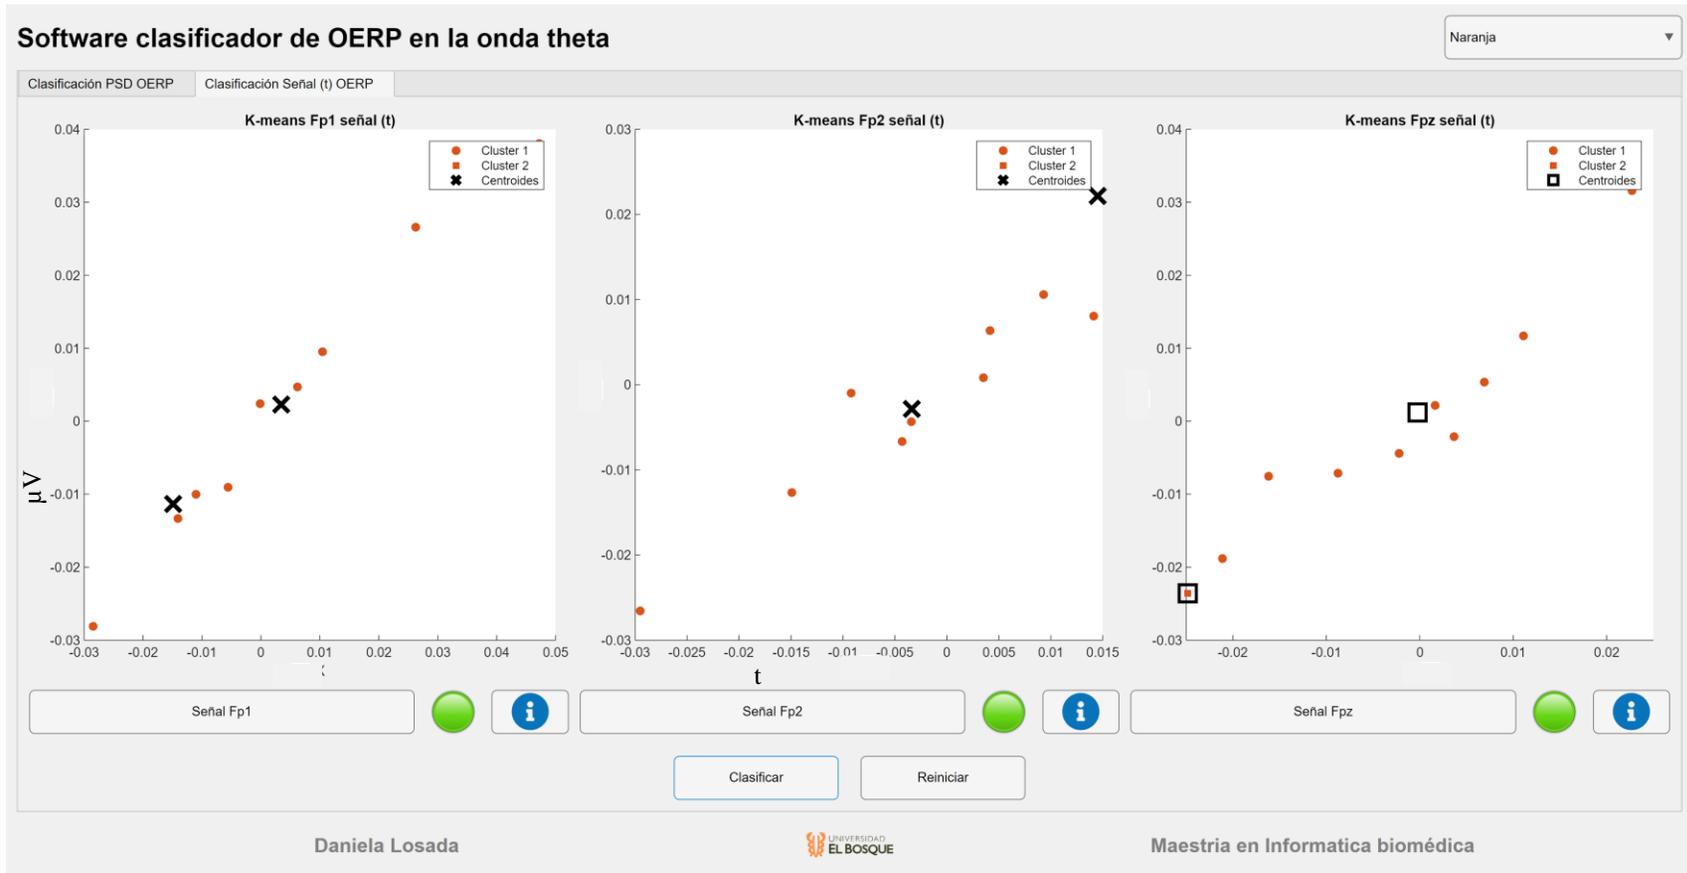


Ilustración 67. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Naranja.

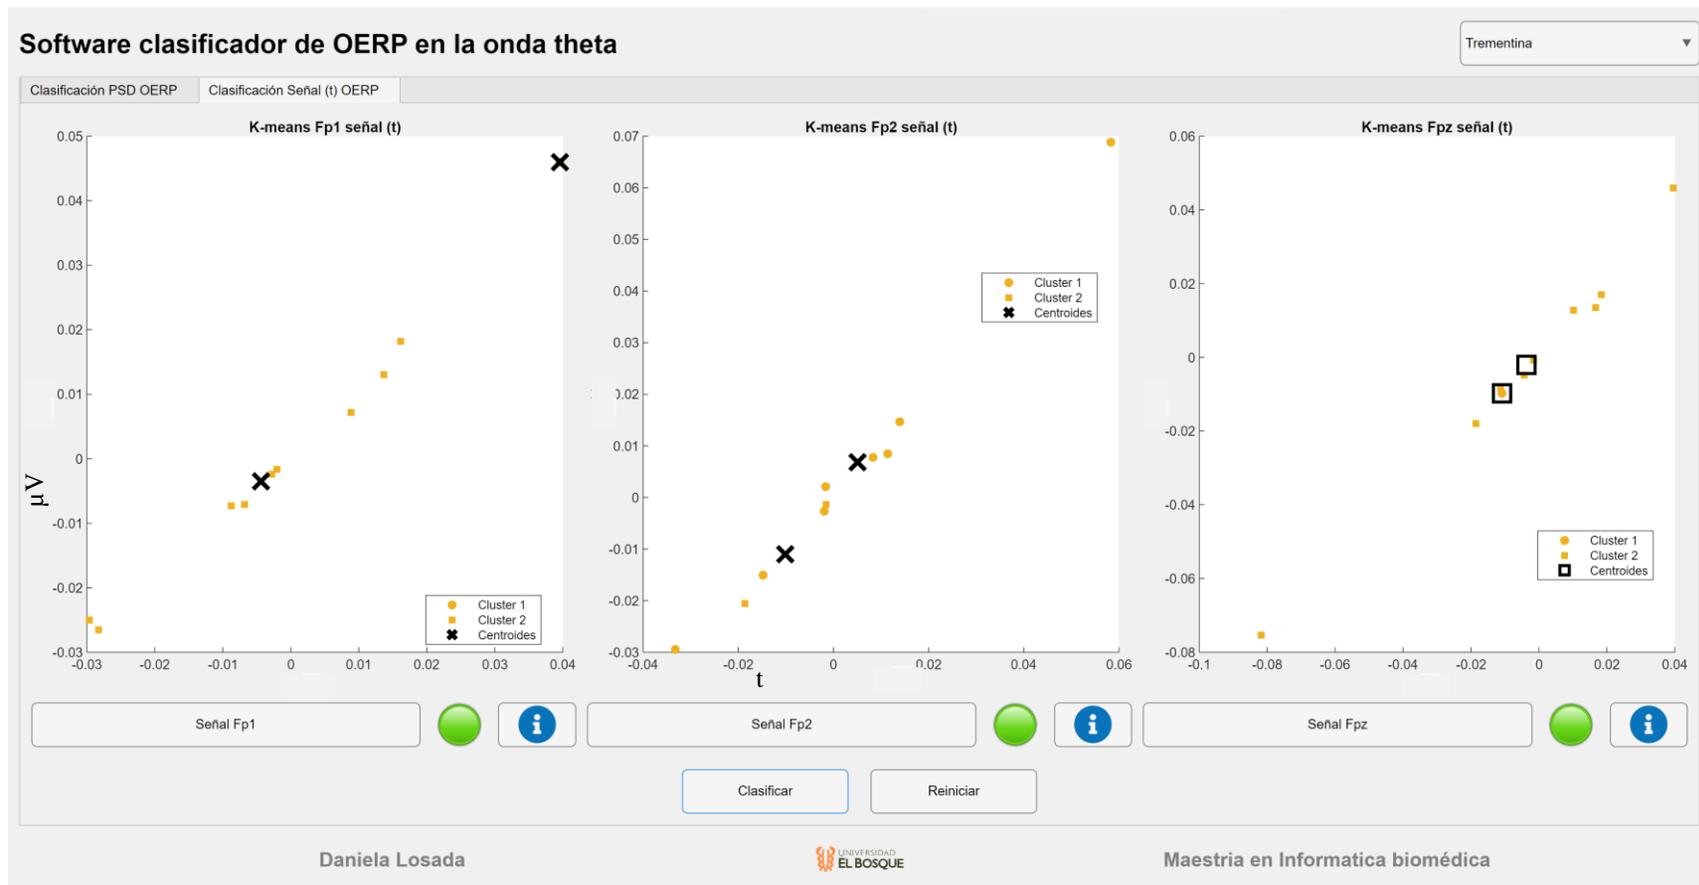


Ilustración 68. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, implementado para la señal proveniente de Fp1, Fp2 y Fpz, en el OERP a Trementina.

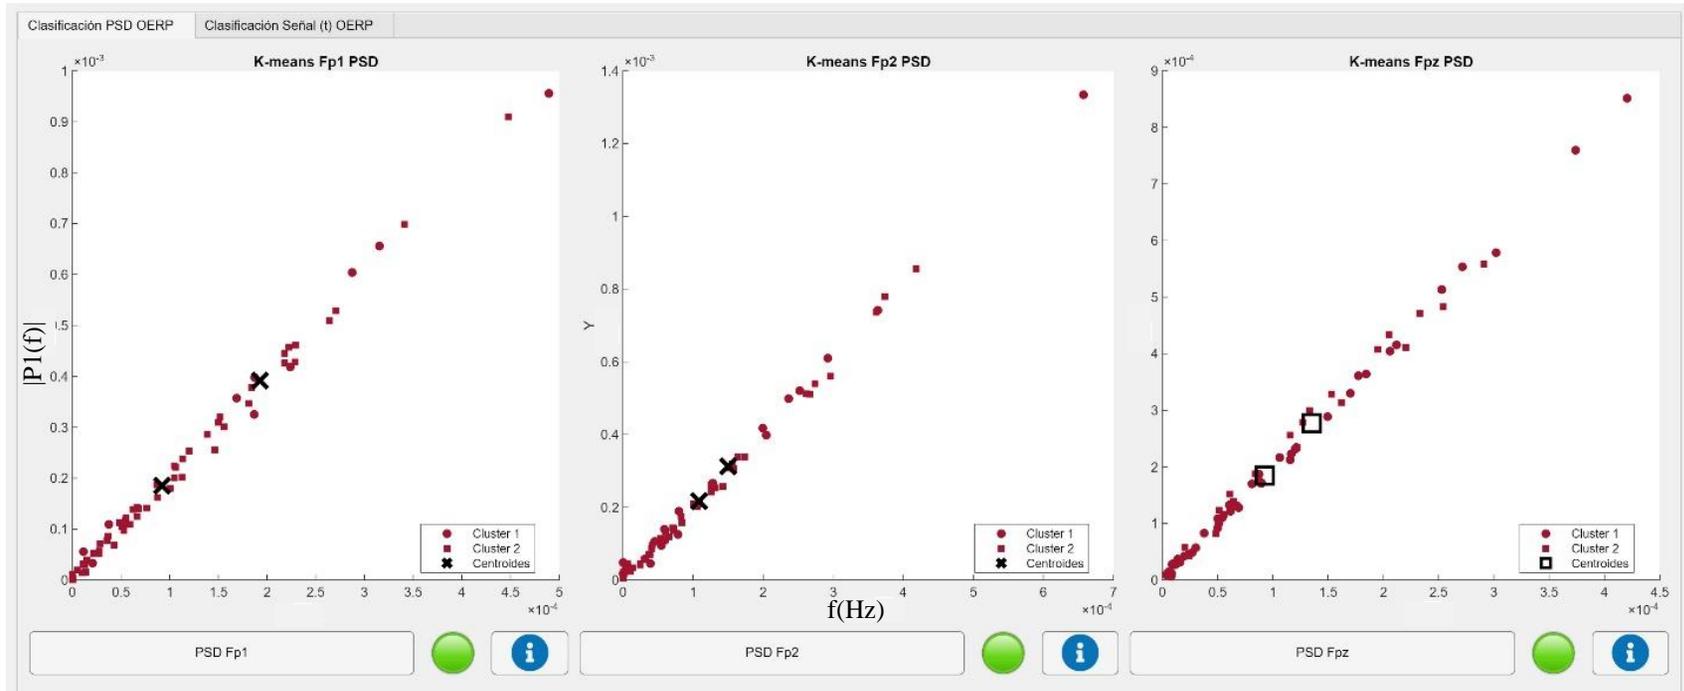


Ilustración 69. K-means correspondiente de la señal resultante del procesamiento de la señal de PSD de 10 sujetos, usando para la señal proveniente de Fp1, Fp2 y Fpz, en los olores a Ajo, Canela, Limón, Manzana, Mental, Naranja, Trementina.

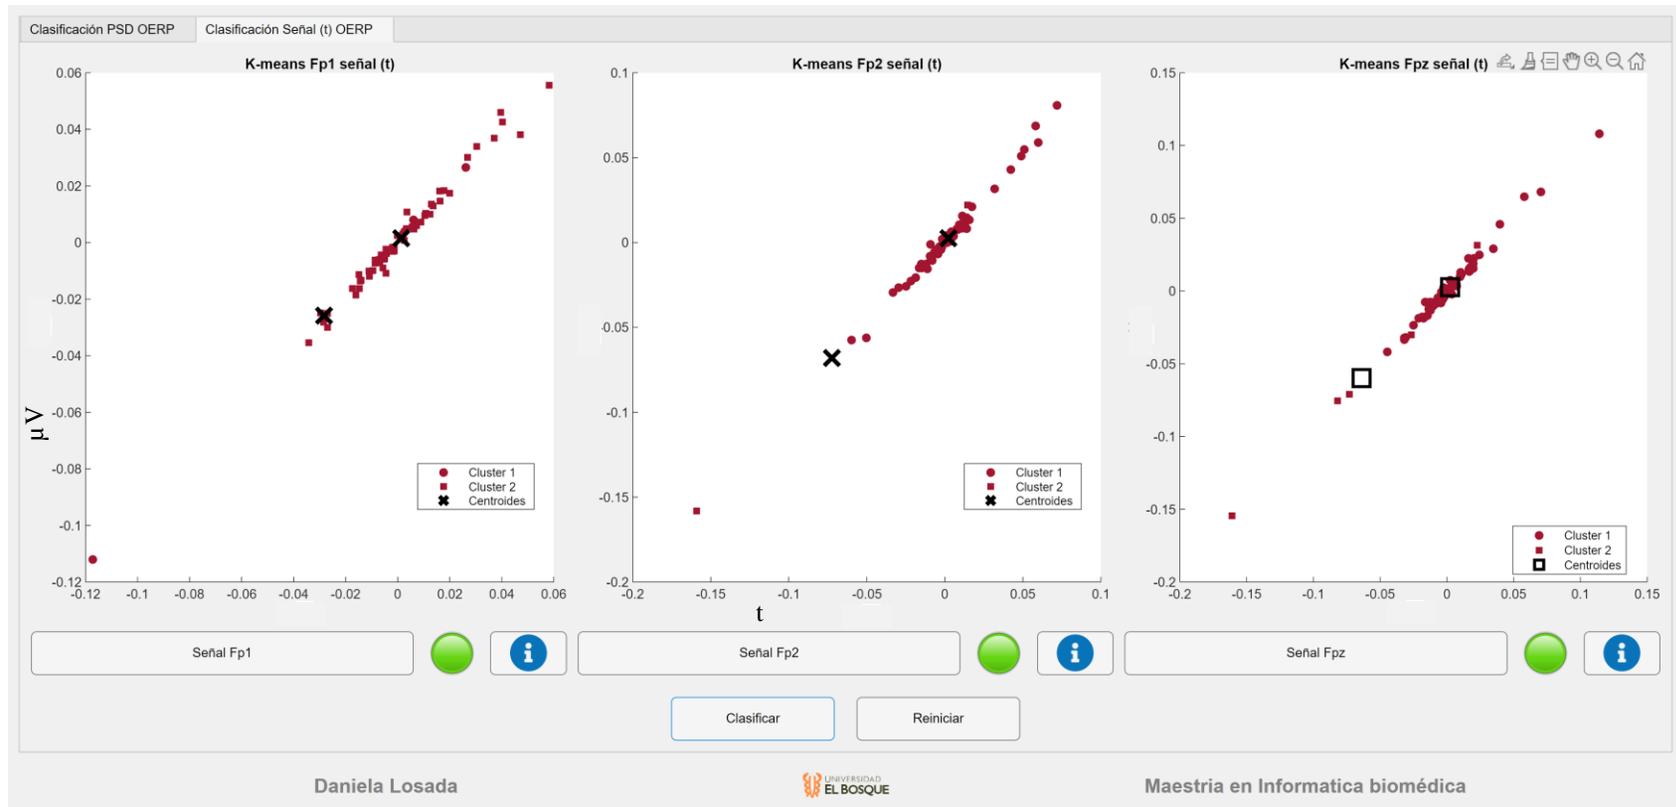


Ilustración 70. K-means correspondiente de la señal en el dominio del tiempo de 10 sujetos, usando para la señal proveniente de Fp1, Fp2 y Fpz, en los olores a Ajo, Canela, Limón, Manzana, Mental, Naranja, Trementina.

Es posible caracterizar los ERP olfativos producidos por el bulbo olfatorio durante la presentación de estímulo olfativo mediante señales electrobulbográficas empleando aprendizaje computacional no supervisado.

Olor (Señal(t))	Fp1		Fp2		Fpz	
	Compacidad	Separabilidad	Compacidad	Separabilidad	Compacidad	Separabilidad
Ajo	[2.931909 0.781429]	0.883985	[3.437759 1.13210]	1.050338	[2.526221 4.292329]	1.589409
Canela	[3.573213 1.411967]	1.188261	[0.575235 5.499781]	0.758443	[3.432158 4.860206]	0.986002
Limón	[4.578046 0.722200]	0.849823	[2.834830 5.434857]	1.683695	[5.705119 1.714040]	1.309213
Manzana	[0.600448 4.624428]	0.774886	[0.672699 5.388360]	0.820182	[0.804895 14.322041]	0.897159
Menta	[2.940201 5.132300]	1.714701	[1.884412 5.555840]	0.595983	[6.651615 1.322626]	0.715999
Naranja	[1.207508 4.339344]	1.098867	[7.455585 0.918145]	0.958199	[3.192256 4.971380]	1.786688
Trementina	[8.731092 2.122761]	0.854231	[4.428306 1.615350]	1.270964	[4.717307 4.376858]	2.171936

Tabla 17. Valor de compacidad y separabilidad correspondiente al K-means de los 7 olores en el dominio del tiempo para los canales Fp1, Fp2 y Fpz.

Olor (PSD)	Fp1		Fp2		Fpz	
	Compacidad	Separabilidad	Compacidad	Separabilidad	Compacidad	Separabilidad
Ajo	[0.000724 0.002382]	0.018189	[0.001663 0.000583]	0.024154	[0.003241 0.001140]	0.036316
Canela	[0.001787 0.000667]	0.025833	[0.000277 0.003506]	0.013174	[0.000590 0.003122]	0.024286
Limón	[0.001869 0.001331]	0.028785	[0.004315 0.000953]	0.032557	[0.001726 0.002639]	0.029470
Manzana	[0.002732 0.000986]	0.052272	[0.001276 0.003033]	0.055076	[0.004659 0.001482]	0.068258
Menta	[0.002497 0.002132]	0.022962	[0.001265 0.001691]	0.035572	[0.000536 0.005634]	0.028836
Naranja	[0.004913 0.000789]	0.023772	[0.000883 0.005399]	0.032223	[0.000979 0.005052]	0.034769
Trementina	[0.004071 0.001067]	0.040421	[0.001580 0.002610]	0.021404	[0.001971 0.003579]	0.059824

Tabla 18. Valor de compacidad y separabilidad correspondiente al K-means de los 7 olores en el PSD para los canales Fp1, Fp2 y Fpz.

5.7.1 Respuesta a la hipótesis

Si, es posible ya que los electros Fp1, Fp2 y Fpz se eligieron de acuerdo con bibliografía que indica que estos canales por su ubicación frontal serian receptores de la señal eléctrica proveniente del bulbo olfatorio. A del análisis estadístico de las medidas de tendencia central y el análisis descriptivo analizado en las gráficas de cajas y bigotes, adicionalmente se analizaron las variaciones de la onda Theta durante el OERP, de acuerdo a las variaciones de las señales en la onda theta el software permite agrupar mediante el algoritmo *K-means* el comportamiento *OERPs* en el dominio del tiempo y el *PSD*, observándose una agrupación más homogénea dada por los datos correspondientes a la señal en el PSD como se observa en el tabla 17 y 18

6 Conclusiones

Para el proceso de caracterización de los *OERPs* provenientes de la onda Theta en los canales Fp1, Fp2 y Fpz se realizó el diseño de un proceso de extracción de características que permite extraer valores cuantitativos para la señal en el dominio del tiempo y del *PSD* el cual fue implementado para los estímulos olfativos de Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina.

El desarrollo de software utilizando *App designer* de Matlab para la caracterización de los *OERPs* olfativos se abordó mediante la implementación de un algoritmo de agrupación *K-means*, para los olores de Ajo, Canela, Limón, Manzana, Menta, Naranja y Trementina, para el análisis de la onda Theta en los canales Fp1, Fp2 y Fpz en el dominio del tiempo y el *PSD*, las medias de calidad interna de los *Clusters* observándose la compacidad y la separabilidad, está medición se desarrolla progresivamente durante la clasificación de los datos implementados.

El *K-means* de la señal el PSD indica homogeneidad y mejor índice de agrupación en los datos como se observa en la Ilustración 69. Mientras que en el *K-means* proveniente de las señales del *PSD* se observa mayor dispersión y dificulta la identificación de los grupos Ilustración 70. Por lo tanto, si se trata de implementar métodos de agrupación se seguirá implementar las señales en el dominio del PSD.

La generalidad del software facilita la implementación de otras bases de datos de señales olfativas de los canales Fp1, Fp2 y Fpz para la caracterización de *OERPs* mediante *K-means*, para esto se debe realizar previamente el procesamiento de la señal en el dominio del tiempo y del *PSD* de la onda Theta, como guía de apoyo para el procesamiento de la señal se encuentra el Anexo 1, que corresponde al código fuente usado es esta investigación.

La caracterización de señales EBG mediante la extracción de características y su categorización de los *OERPS*, es un potencial apoyo del diagnóstico clínico, esto puede tener implicaciones en el entendimiento de alteraciones olfativas y enfermedades neurodegenerativas dado a la naturaleza cuantitativa de los datos obtenidos mediante la implantación del software desarrollado en este proyecto.

El desarrollo tecnológico realizado, acerca a los investigadores con conocimientos no específicos en programación de aprendizaje no supervisado en el procesamiento de señales, a identificar y caracterizar de forma práctica los *OPERS*, aportando en el campo en la educación, investigación y prototipado en apoyo diagnóstico.

7 Trabajos futuros

En futuras investigaciones se recomienda realizar adquisición de las señales EBG olfativas para aumentar el número de la muestra y así obtener mayor entrenamiento del algoritmo, es importante que el grupo de muestra contenga sujetos con alteraciones neurodegenerativas y/o olfativas temporal a consecuencias del Covid-19, se sugiere extender el análisis a diferentes tipos de olores y ondas cerebrales como lo es Ondas delta, alfa, beta y gamma, para obtener un análisis diferencial con mayor integralidad.

Se recomienda trabajar con segmentos de tiempo más reducidos, debido al analizar 6 segundos de muestras se pueden dar varias inhalaciones olfativas, dando la posibilidad de producir variaciones en la señal.

Adicionalmente se sugiere realizar análisis del segmento de la señal en reposo para identificar estadísticamente que existe una relación diferencial con el *OERP* y el estado de reposo (sin exposición al olor).

En próximas investigaciones se sugiere la implementación de un análisis diferencial de la relación entre la señal superpuesta del potencial evocado y la señal en reposo para realizando análisis estadístico de las variaciones significativas, correspondientes a los estímulos olfativos, siendo pertinente el análisis en el dominio de la frecuencia, tiempo-frecuencia para obtener mayor resolución en la caracterización y clasificación del *OERP*, además se plantea la implementación de al menos tres algoritmos como por ejemplo redes neuronales, agrupación jerárquica, detección de anomalías, entre otros.

8 Anexos

```
%% SEGMENTACION DE LA SEÑAL  
clear all
```

```
clc
close all
subj1 = load('Asujeto_record.mat');

fs=250;

x= subj1.record(1,:);% seleccionas el canal de entrada
x2= subj1.record(2,:);
x3= subj1.record(3,:);

Fp1_1=x/max(x);%normalidadion de la señal
Fp1_1 = bandpass(Fp1_1,[4 7],fs);% theta
Fp1_1= Fp1_1(3000:4500);% segmetación
Fp2_1=x2/max(x2);
Fp2_1 = bandpass(Fp2_1,[4 7],fs);% theta
Fp2_1= Fp2_1(3000:4500);% segmetación
Fpz_1=x3/max(x3);
Fpz_1 = bandpass(Fpz_1,[4 7],fs);% theta
Fpz_1= Fpz_1(3000:4500);% segmetación

t=((0:length(Fp1_1)-1)*(1/fs));%asignacion de los ejesx(tiempo)
subj2 = load('Bsujeeto_record.mat');
Sfp1_1 = Fp1_1;
Sfp2_1 = Fp2_1;
Sfpz_1 = Fpz_1;

x= subj2.record(1,:);% seleccionas el canal de entrada
x2= subj2.record(2, :);
x3= subj2.record(3,:);

Fp1_2 = x/max(x);%normalidadion de la señal
Fp1_2 = bandpass(Fp1_2,[4 7],fs);% theta
Fp1_2= Fp1_2(3000:4500);% segmetación
Fp2_2 = x2/max(x2);
Fp2_2 = bandpass(Fp2_2,[4 7],fs);% theta
Fp2_2 = Fp2_2(3000:4500);% segmetación
Fpz_2 = x3/max(x3);
Fpz_2 = bandpass(Fpz_2,[4 7],fs);% theta
Fpz_2= Fpz_2(3000:4500);% segmetación

Sfp1_2 = Fp1_2;
Sfp2_2 = Fp2_2;
Sfpz_2 = Fpz_2;

subj3 = load('Csujeeto_record.mat');

x= subj3.record(1,:);% seleccionas el canal de entrada
x2= subj3.record(2, :);
x3= subj3.record(3,:);

Fp1_3 = x/max(x);%normalidadion de la señal
Fp1_3 = bandpass(Fp1_3,[4 7],fs);% theta
Fp1_3 = Fp1_3(3000:4500);% segmetación
```

```
Fp2_3 = x2/max(x2);
Fp2_3 = bandpass(Fp2_3,[4 7],fs);% theta
Fp2_3 = Fp2_3(3000:4500);% segmetación
Fpz_3 = x3/max(x3);
Fpz_3 = bandpass(Fpz_3,[4 7],fs);% theta
Fpz_3 = Fpz_3(3000:4500);% segmetación

Sfp1_3 = Fp1_3;
Sfp2_3 = Fp2_3;
Sfpz_3 = Fpz_3;

subj4 = load('Dsujeeto_f_record.mat');

x=  suj4.record(1,:);% seleccionas el canal de entrada
x2= suj4.record(2, :);
x3= suj4.record(3,:);

Fp1_4=x/max(x);%normalidadion de la señal
Fp1_4 = bandpass(Fp1_4,[4 7],fs);% theta
Fp1_4= Fp1_4(3000:4500);% segmetación
Fp2_4=x2/max(x2);
Fp2_4 = bandpass(Fp2_4,[4 7],fs);% theta
Fp2_4= Fp2_4(3000:4500);% segmetación
Fpz_4=x3/max(x3);
Fpz_4 = bandpass(Fpz_4,[4 7],fs);% theta
Fpz_4= Fpz_4(3000:4500);% segmetación

Sfp1_4 = Fp1_4;
Sfp2_4 = Fp2_4;
Sfpz_4 = Fpz_4;

subj5 = load('Esujeeto_record.mat');

x=  suj5.record(1,:);% seleccionas el canal de entrada
x2= suj5.record(2, :);
x3= suj5.record(3,:);

Fp1_5=x/max(x);%normalidadion de la señal
Fp1_5 = bandpass(Fp1_5,[4 7],fs);% theta
Fp1_5 = Fp1_5(3000:4500);% segmetación
Fp2_5=x2/max(x2);
Fp2_5 = bandpass(Fp2_5,[4 7],fs);% theta
Fp2_5 = Fp2_5(3000:4500);% segmetación
Fpz_5=x3/max(x3);
Fpz_5 = bandpass(Fpz_5,[4 7],fs);% theta
Fpz_5= Fpz_5(3000:4500);% segmetación

Sfp1_5 = Fp1_5;
Sfp2_5 = Fp2_5;
Sfpz_5 = Fpz_5;

subj6 = load('Fsujeeto_record.mat');
```

```
x= suj6.record(1,:);% seleccionas el canal de entrada
x2= suj6.record(2, :);
x3= suj6.record(3,:);
```

```
Fp1_6=x/max(x);%normalidadion de la señal
Fp1_6 = bandpass(Fp1_6,[4 7],fs);% theta
Fp1_6= Fp1_6(3000:4500);% segmetación
Fp2_6=x2/max(x2);
Fp2_6 = bandpass(Fp2_6,[4 7],fs);% theta
Fp2_6= Fp2_6(3000:4500);% segmetación
Fpz_6=x3/max(x3);
Fpz_6 = bandpass(Fpz_6,[4 7],fs);% theta
Fpz_6= Fpz_6(3000:4500);% segmetación
```

```
Sfp1_6 = Fp1_6;
Sfp2_6 = Fp2_6;
Sfpz_6 = Fpz_6;
```

```
suj7 = load('Gsujeto_record.mat');
```

```
x= suj7.record(1,:);% seleccionas el canal de entrada
x2= suj7.record(2, :);
x3= suj7.record(3,:);
```

```
Fp1_7 = x/max(x);%normalidadion de la señal
Fp1_7 = bandpass(Fp1_7,[4 7],fs);% theta
Fp1_7 = Fp1_7(3000:4500);% segmetación
Fp2_7=x2/max(x2);
Fp2_7 = bandpass(Fp2_7,[4 7],fs);% theta
Fp2_7= Fp2_7(3000:4500);% segmetación
Fpz_7=x3/max(x3);
Fpz_7 = bandpass(Fpz_7,[4 7],fs);% theta
Fpz_7= Fpz_7(3000:4500);% segmetación
```

```
Sfp1_7 = Fp1_7;
Sfp2_7 = Fp2_7;
Sfpz_7 = Fpz_7;
```

```
suj8 = load('Hsujeto_record.mat');
```

```
x= suj8.record(1,:);% seleccionas el canal de entrada
x2= suj8.record(2, :);
x3= suj8.record(3,:);
```

```
Fp1_8 = x/max(x);%normalidadion de la señal
Fp1_8 = bandpass(Fp1_8,[4 7],fs);% theta
Fp1_8 = Fp1_8(3000:4500);% segmetación
Fp2_8=x2/max(x2);
Fp2_8 = bandpass(Fp2_8,[4 7],fs);% theta
Fp2_8= Fp2_8(3000:4500);% segmetación
Fpz_8=x3/max(x3);
Fpz_8 = bandpass(Fpz_8,[4 7],fs);% theta
Fpz_8= Fpz_8(3000:4500);% segmetación
```

```
Sfp1_8 = Fp1_8;
```

```
Sfp2_8 = Fp2_8;
Sfpz_8 = Fpz_8;

subj9 = load('Isujeto_record.mat');

x= subj9.record(1,:);% seleccionas el canal de entrada
x2= subj9.record(2, :);
x3= subj9.record(3,:);

Fp1_9 = x/max(x);%normalidadion de la señal
Fp1_9 = bandpass(Fp1_9,[4 7],fs);% theta
Fp1_9 = Fp1_9(3000:4500);% segmetación
Fp2_9=x2/max(x2);
Fp2_9 = bandpass(Fp2_9,[4 7],fs);% theta
Fp2_9= Fp2_9(3000:4500);% segmetación
Fpz_9=x3/max(x3);
Fpz_9 = bandpass(Fpz_9,[4 7],fs);% theta
Fpz_9= Fpz_9(3000:4500);% segmetación
Sfp1_9 = Fp1_9;
Sfp2_9 = Fp2_9;
Sfpz_9 = Fpz_9;

subj10 = load('Jsujeto_record.mat');

x= subj10.record(1,:);% seleccionas el canal de entrada
x2= subj10.record(2, :);
x3= subj10.record(3,:);

Fp1_10 = x/max(x);%normalidadion de la señal
Fp1_10 = bandpass(Fp1_10,[4 7],fs);% theta
Fp1_10 = Fp1_10(3000:4500);% segmetación
Fp2_10=x2/max(x2);
Fp2_10 = bandpass(Fp2_10,[4 7],fs);% theta
Fp2_10 = Fp2_10(3000:4500);% segmetación
Fpz_10 =x3/max(x3);
Fpz_10 = bandpass(Fpz_10,[4 7],fs);% theta
Fpz_10 = Fpz_10(3000:4500);% segmetación

Sfp1_10 = Fp1_10;
Sfp2_10 = Fp2_10;
Sfpz_10 = Fpz_10;

figure (8)
plot(t,Fpz_2,t,Fpz_1,t,Fpz_3,t,Fpz_4,t,Fpz_5,t,Fpz_6,t,Fpz_7,t,Fpz_8,t,Fpz_9,t,Fpz_10
)
title('Olor Naranja Fpz en (t)')
figure (9)
plot(t,Fp1_2,t,Fp1_1,t,Fp1_3,t,Fp1_4,t,Fp1_5,t,Fp1_6,t,Fp1_7,t,Fp1_8,t,Fp1_9,t,Fp1_10
)
title('Olor Naranja en Fp1 (t)')
figure (10)
plot(t,Fp2_2,t,Fp2_1,t,Fp2_3,t,Fp2_4,t,Fp2_5,t,Fp2_6,t,Fp2_7,t,Fp2_8,t,Fp2_9,t,Fp2_10
)
title('Olor Naranja en Fp2 (t)')
%%
```

```
%% Sejeta 1 Naranja
L = length(Fp1_1);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp1_1 = fft(Fp1_1); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp1_1/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_1= P1
figure (1)
subplot (1,10,1);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑ±al X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
```

```
L = length(Fp2_1);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp2_1 = fft(Fp2_1); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp2_1/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_1 = P1
figure (2)
subplot (1,10,1);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑ±al X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
```

```
L = length(Fpz_1);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fpz_1 = fft(Fpz_1); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fpz_1/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
```

```
Fpz_1 = P1
figure (3)
subplot (1,10,1);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

%%
%% Sejeto 2 Naranja
L = length(Fp1_2);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp1_2 = fft(Fp1_2); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp1_2/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_2 = P1
figure (1)
subplot (1,10,2);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fp2_2);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp2_2 = fft(Fp2_2); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp2_2/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_2 = P1
figure (2)
subplot (1,10,2);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fpz_2);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
```

```

f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fpz_2 = fft(Fpz_2); %Calculating the Fourier Transform of seÑal
P2 = abs(Fpz_2/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fpz_2 = P1
figure (3)
subplot (1,10,2);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
%%
%% Sejeto 3 Naranja
L = length(Fp1_3);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido aÑadido. Como promedio, las seÑales
m3s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp1_3 = fft(Fp1_3); %Calculating the Fourier Transform of seÑal
P2 = abs(Fp1_3/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_3 = P1
figure (1)
subplot (1,10,3);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fp2_3);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido aÑadido. Como promedio, las seÑales
m3s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp2_3 = fft(Fp2_3); %Calculating the Fourier Transform of seÑal
P2 = abs(Fp2_3/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_3 = P1
figure (2)
subplot (1,10,3);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su
rango de frecuencias
xlabel('f (Hz)')

```

```
ylabel('|P1(f)|')
```

```
L = length(Fpz_3);% Se define el dominio de la frecuencia f y se representa  
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente  
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las se±ales  
m±as largas producen mejores aproximaciones de frecuencia.
```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de  
Frecuencias)
```

```
Fpz_3 = fft(Fpz_3); %Calculating the Fourier Transform of se±al
```

```
P2 = abs(Fpz_3/L);% Power Spectral Density (Espectro de Potencia estimado desde la  
FFT de X)
```

```
P1 = P2(1:L/2+1);% El espectro es una funci±n con dos lados iguales, se toma uno de  
los lados.
```

```
P1(2:end-1) = 2*P1(2:end-1);
```

```
Fpz_3 = P1
```

```
figure (3)
```

```
subplot (1,10,3);
```

```
plot(f,P1);% Se grafica el espectro de potencia P1 de la se±al X considerando su  
rango de frecuencias
```

```
xlabel('f (Hz)')
```

```
ylabel('|P1(f)|')
```

```
%%
```

```
%% Sejeto 4 Naranja
```

```
L = length(Fp1_4);% Se define el dominio de la frecuencia f y se representa  
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente  
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las se±ales  
m±as largas producen mejores aproximaciones de frecuencia.
```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de  
Frecuencias)
```

```
Fp1_4 = fft(Fp1_4); %Calculating the Fourier Transform of se±al
```

```
P2 = abs(Fp1_3/L);% Power Spectral Density (Espectro de Potencia estimado desde la  
FFT de X)
```

```
P1 = P2(1:L/2+1);% El espectro es una funci±n con dos lados iguales, se toma uno de  
los lados.
```

```
P1(2:end-1) = 2*P1(2:end-1);
```

```
Fp1_4 = P1
```

```
figure (1)
```

```
subplot (1,10,4);
```

```
plot(f,P1);% Se grafica el espectro de potencia P1 de la se±al X considerando su  
rango de frecuencias
```

```
xlabel('f (Hz)')
```

```
ylabel('|P1(f)|')
```

```
L = length(Fp2_4);% Se define el dominio de la frecuencia f y se representa  
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente  
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las se±ales  
m±as largas producen mejores aproximaciones de frecuencia.
```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de  
Frecuencias)
```

```
Fp2_4 = fft(Fp2_4); %Calculating the Fourier Transform of se±al
```

```
P2 = abs(Fp2_4/L);% Power Spectral Density (Espectro de Potencia estimado desde la  
FFT de X)
```

```
P1 = P2(1:L/2+1);% El espectro es una funci±n con dos lados iguales, se toma uno de  
los lados.
```

```
P1(2:end-1) = 2*P1(2:end-1);
```

```
Fpz_4 = P1
figure (2)
subplot (1,10,4);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fpz_4);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
m±is largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fpz_4 = fft(Fpz_4); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fpz_4/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÃ³n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fpz_4 = P1
figure (3)
subplot (1,10,4);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

%%
%% Sejeto 5 Naranja
L = length(Fp1_5);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
m±is largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp1_5 = fft(Fp1_5); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp1_5/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÃ³n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_5 = P1
figure (1)
subplot (1,10,5);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fp2_5);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
m±is largas producen mejores aproximaciones de frecuencia.
```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp2_5 = fft(Fp2_5); %Calculating the Fourier Transform of seÑal
P2 = abs(Fp2_5/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_5 = P1
figure (2)
subplot (1,10,5);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
```

L = length(Fpz_5);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido aÑadido. Como promedio, las seÑales
m3s largas producen mejores aproximaciones de frecuencia.

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fpz_5 = fft(Fpz_5); %Calculating the Fourier Transform of seÑal
P2 = abs(Fpz_5/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fpz_5 = P1
figure (3)
subplot (1,10,5);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
```

```
%%
```

```
%% Sejeto 6 Naranja
```

L = length(Fp1_6);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido aÑadido. Como promedio, las seÑales
m3s largas producen mejores aproximaciones de frecuencia.

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp1_6 = fft(Fp1_6); %Calculating the Fourier Transform of seÑal
P2 = abs(Fp1_6/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_6 = P1
figure (1)
subplot (1,10,6);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su
rango de frecuencias
xlabel('f (Hz)')
```

```
ylabel('|P1(f)|')
```

```
L = length(Fp2_6);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
```

```
Fp2_6 = fft(Fp2_6); %Calculating the Fourier Transform of seÑ±al
```

```
P2 = abs(Fp2_6/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
```

```
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
```

```
P1(2:end-1) = 2*P1(2:end-1);
```

```
Fp2_6 = P1
```

```
figure (2)
```

```
subplot (1,10,6);
```

```
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑ±al X considerando su
rango de frecuencias
```

```
xlabel('f (Hz)')
```

```
ylabel('|P1(f)|')
```

```
L = length(Fpz_6);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
```

```
Fpz_6 = fft(Fpz_6); %Calculating the Fourier Transform of seÑ±al
```

```
P2 = abs(Fpz_6/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
```

```
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
```

```
P1(2:end-1) = 2*P1(2:end-1);
```

```
Fpz_6 = P1
```

```
figure (3)
```

```
subplot (1,10,6);
```

```
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑ±al X considerando su
rango de frecuencias
```

```
xlabel('f (Hz)')
```

```
ylabel('|P1(f)|')
```

```
%%
```

```
%% Sejeto 7 Naranja
```

```
L = length(Fp1_7);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
```

```
Fp1_7 = fft(Fp1_7); %Calculating the Fourier Transform of seÑ±al
```

```
P2 = abs(Fp1_7/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
```

```
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
```

```
P1(2:end-1) = 2*P1(2:end-1);
```

```

Fp1_7 = P1
figure (1)
subplot (1,10,7);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fp2_7);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp2_7 = fft(Fp2_7); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp2_7/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_7 = P1
figure (2)
subplot (1,10,7);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fpz_7);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fpz_7 = fft(Fpz_7); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fpz_7/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fpz_7 = P1
figure (3)
subplot (1,10,7);
plot(f,P1);% Se grafica el espectro de potencia P1 de la señal X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

%%
%% Sejeto 8 Naranja
L = length(Fp1_8);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.

```

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de Frecuencias)
Fp1_8 = fft(Fp1_8); %Calculating the Fourier Transform of seÑal
P2 = abs(Fp1_8/L);% Power Spectral Density (Espectro de Potencia estimado desde la FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_8 = P1
figure (1)
subplot (1,10,8);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
```

L = length(Fp2_8);% Se define el dominio de la frecuencia f y se representa graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente de 0,7 y 1, como se esperaba, debido al ruido aÑadido. Como promedio, las seÑales mÃ¡s largas producen mejores aproximaciones de frecuencia.

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de Frecuencias)
Fp2_8 = fft(Fp2_8); %Calculating the Fourier Transform of seÑal
P2 = abs(Fp2_8/L);% Power Spectral Density (Espectro de Potencia estimado desde la FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_8 = P1
figure (2)
subplot (1,10,8);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
```

L = length(Fpz_8);% Se define el dominio de la frecuencia f y se representa graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente de 0,7 y 1, como se esperaba, debido al ruido aÑadido. Como promedio, las seÑales mÃ¡s largas producen mejores aproximaciones de frecuencia.

```
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de Frecuencias)
Fpz_8 = fft(Fpz_8); %Calculating the Fourier Transform of seÑal
P2 = abs(Fpz_8/L);% Power Spectral Density (Espectro de Potencia estimado desde la FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fpz_8 = P1
figure (3)
subplot (1,10,8);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')
```

```

%%
%% Sejeta 9 Naranja
L = length(Fp1_9);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp1_9 = fft(Fp1_9); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp1_9/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_9 = P1
figure (1)

subplot (1,10,9);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑ±al X considerando su
rango de frecuencias
title(t,'PSD Theta Fp1(t)Naranja');
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fp2_9);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp2_9 = fft(Fp2_9); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fp2_9/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÑ±n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_9 = P1
figure (2)
subplot (1,10,9);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑ±al X considerando su
rango de frecuencias
title(t,'PSD Theta Fp2(t)Naranja');
xlabel('f (Hz)')
ylabel('|P1(f)|')
L = length(Fpz_9);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido añ±adido. Como promedio, las seÑ±ales
mÑ±s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fpz_9 = fft(Fpz_9); %Calculating the Fourier Transform of seÑ±al
P2 = abs(Fpz_9/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)

```

```

P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fpz_9 = P1
figure (3)
subplot (1,10,9);
plot(f,P1);% Se grafica el espectro de potencia P1 de la se1al X considerando su
rango de frecuencias

xlabel('f (Hz)')
ylabel('|P1(f)|')
%%
%% Sejeta 10 Naranja
L = length(Fp1_10);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido a1adido. Como promedio, las se1ales
m1is largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp1_10 = fft(Fp1_10); %Calculating the Fourier Transform of se1al
P2 = abs(Fp1_10/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp1_10 = P1
figure (1)
subplot (1,10,10);
plot(f,P1);% Se grafica el espectro de potencia P1 de la se1al X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fp2_10);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente
de 0,7 y 1, como se esperaba, debido al ruido a1adido. Como promedio, las se1ales
m1is largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fp2_10 = fft(Fp2_10); %Calculating the Fourier Transform of se1al
P2 = abs(Fp2_10/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funci3n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fp2_10 = P1
figure (2)
subplot (1,10,10);
plot(f,P1);% Se grafica el espectro de potencia P1 de la se1al X considerando su
rango de frecuencias
xlabel('f (Hz)')
ylabel('|P1(f)|')

L = length(Fpz_10);% Se define el dominio de la frecuencia f y se representa
graficamente el espectro de amplitud unilateral P1. Las amplitudes no son exactamente

```

```
de 0,7 y 1, como se esperaba, debido al ruido añadido. Como promedio, las seÑales
mÃ¡s largas producen mejores aproximaciones de frecuencia.
f = fs*(0:(L/2))/L;% Se Calcula el rango de frecuencias del espectro (Vector de
Frecuencias)
Fpz_10 = fft(Fpz_10); %Calculating the Fourier Transform of seÑal
P2 = abs(Fpz_10/L);% Power Spectral Density (Espectro de Potencia estimado desde la
FFT de X)
P1 = P2(1:L/2+1);% El espectro es una funciÃ³n con dos lados iguales, se toma uno de
los lados.
P1(2:end-1) = 2*P1(2:end-1);
Fpz_10 = P1
figure (3)
subplot (1,10,10);
plot(f,P1);% Se grafica el espectro de potencia P1 de la seÑal X considerando su
rango de frecuencias
title(t,'PSD Theta Fpz(t)Naranja');
xlabel('f (Hz)')
ylabel('|P1(f)|')

rng(1); % Establecer la semilla para reproducibilidad
Fp1 =[Fp1_1; Fp1_2; Fp1_3; Fp1_4; Fp1_5; Fp1_6; Fp1_7; Fp1_8; Fp1_9; Fp1_10];
Fp2 =[Fp2_1; Fp2_2; Fp2_3; Fp2_4; Fp2_5; Fp2_6; Fp2_7; Fp2_8; Fp2_9; Fp2_10];
Fpz = [Fpz_1; Fpz_2; Fpz_3; Fpz_4; Fpz_5; Fpz_6; Fpz_7; Fpz_8; Fpz_9; Fpz_10];

% Combinar los datos
allData = [Fp1; Fp2; Fpz];

% Especificar el nÃºmero de clusters (k)
k = 3;

% Aplicar K-means
idx = kmeans(allData, k);

% Asignar colores a cada grupo
colors = lines(k);

% Visualizar los resultados
figure;
hold on;
for i = 1:k
    scatter3(allData(idx == i, 1), allData(idx == i, 2), allData(idx == i, 3), 50,
'y', 'filled');
end
title('Naranja de K-means');
xlabel('Feature 1');
ylabel('Feature 2');
zlabel('Feature 3');

% Mostrar informaci3n sobre los centroides
centroids = zeros(k, size(allData, 2));
for i = 1:k
    centroids(i, :) = mean(allData(idx == i, :));
end
disp('Centroides:');
```

```
disp(centroids)
%%
% Especificar el número de clusters (k)
k = 2;

% Aplicar K-means
[idx1, centroids] = kmeans(Fp1, k);

% Visualizar los resultados
figure;
gscatter(Fp1(:,1), Fp1(:,2), idx1, 'r', 'o');
hold on;
plot(centroids(:,1), centroids(:,2), 'kx', 'MarkerSize', 15, 'LineWidth', 3);
title('Fp1 K-means');
legend('Cluster 1', 'Cluster 2', 'Centroides');

% Mostrar información sobre los centroides
disp('Centroides:');
disp(centroids);
%%
% Especificar el número de clusters (k)
k = 2;

% Aplicar K-means
[idx2, centroids] = kmeans(Fp2, k);

% Visualizar los resultados
figure;
gscatter(Fp2(:,1), Fp2(:,2), idx2, 'r', 'o');
hold on;
plot(centroids(:,1), centroids(:,2), 'kx', 'MarkerSize', 15, 'LineWidth', 3);
title('Fp2 K-means');
legend('Cluster 1', 'Cluster 2', 'Centroides');

% Mostrar información sobre los centroides
disp('Centroides:');
disp(centroids);
%%
% Especificar el número de clusters (k)
k = 2;

% Aplicar K-means
[idx3, centroids] = kmeans(Fpz, k);

% Visualizar los resultados
figure;
gscatter(Fpz(:,1), Fpz(:,2), idx3, 'r', 'o');
hold on;
plot(centroids(:,1), centroids(:,2), 'kx', 'MarkerSize', 15, 'LineWidth', 3);
title('Fpz K-means');
legend('Cluster 1', 'Cluster 2', 'Centroides');

% Mostrar información sobre los centroides
disp('Centroides:');
disp(centroids);
```

Anexo 1. Código fuente para el procesamiento, segmentación, y extracción de características en el dominio del tiempo y la frecuencia.

Sujeto	Ajo Fp1		Ajo Fp2		Ajo Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Sujeto1	4,99667	0,0153223	4,99667	0,0110422	3,99734	0,00795827
Sujeto2	3,99734	0,00741082	6,32911	0,00951364	4,99667	0,0100173
Sujeto3	4,33045	0,00367861	4,33045	0,00477399	4,33045	0,01276
Sujeto4	4,33045	0,00367861	3,99734	0,0051046	6,49567	0,0158533
Sujeto5	4,99667	0,00715947	4,33045	0,00782146	5,82945	0,021489
Sujeto6	4,99667	0,00617791	7,16189	0,00659094	5,82945	0,00477445
Sujeto7	5,82945	0,0174426	5,996	0,0124528	4,497	0,00460836
Sujeto8	5,996	0,00320599	5,82945	0,00233387	4,497	0,00460836
Sujeto9	5,49634	0,011891	5,996	0,0127697	4,33045	0,00319077
Sujeto10	4,83011	0,00933805	4,33045	0,0156365	6,66223	0,0200018
Medidas de tendencia central						
Des. Estándar	0,654317291	0,004962071	1,073674674	0,004201704	0,975769321	0,006725771
Media	4,98002	0,008530536	5,32978	0,00880397	5,14657	0,010526161
Moda	4,99667	0,00367861	4,33045	NA	4,33045	0,00460836
Moda	NA	NA	NA	NA	5,82945	NA
Moda	NA	NA	NA	NA	4,497	NA

Anexo 2. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a ajo, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

Sujeto	Canela Fp1		Canela Fp2		Canela Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Sujeto1	5,16322	0,0103049	4,83011	0,0120317	6,66223	0,00888422
Sujeto2	5,32978	0,0149417	5,82945	0,0169075	5,32978	0,017742
Sujeto3	5,82945	0,00635624	4,66356	0,00603897	5,82945	0,0109627
Sujeto4	5,82945	0,00635624	3,83078	0,00443199	6,16256	0,0124203
Sujeto5	4,49700	0,00961299	4,99667	0,013694	4,99667	0,0196894
Sujeto6	6,16256	0,0161559	4,497	0,017797	6,16256	0,0185807
Sujeto7	4,16389	0,0175648	4,16389	0,0194967	6,996	0,0168909
Sujeto8	6,16256	0,00571137	7,16189	0,00515946	6,16156	0,00840164
Sujeto9	6,99534	0,0115129	5,82945	0,00939057	5,82945	0,00287202
Sujeto10	3,83078	0,00665641	3,83078	0,0118917	3,83078	0,0118507
Medidas de tendencia central						

Des. Estándar	0,996864774	0,004416167	1,04693319	0,005397361	0,901439459	0,005371687
Media	5,39640	0,010517345	4,96336	0,011683959	5,79610	0,012829458
Moda	5,82945	0,00635624	5,82945	NA	5,82945	NA
Moda	6,16256	NA	3,83078	NA	6,16256	NA

Anexo 3. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a canela, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

Sujeto	Limón Fp1		Limón Fp2		Limón Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Sujeto1	3,83078	0,0109179	3,83978	0,0117182	3,8307	0,0131699
Sujeto2	4,33045	0,0101759	6,66223	0,00981463	4,33045	0,0137517
Sujeto3	3,99734	0,0119215	4,33045	0,0106131	4,33045	0,0142402
Sujeto4	3,99734	0,0119215	4,16389	0,00876258	4,16389	0,00357598
Sujeto5	4,33045	0,00515184	3,99734	0,0115163	5,996	0,010094
Sujeto6	6,16156	0,0219342	6,32911	0,0221105	6,32911	0,0155258
Sujeto7	6,82878	0,0146192	5,32978	0,0195378	5,32978	0,0253948
Sujeto8	4,33045	0,00488795	6,32911	0,00257244	6,49567	0,00638226
Sujeto9	4,33045	0,0111143	4,83011	0,0186519	4,83011	0,00245804
Sujeto10	7,16189	0,010445	7,16189	0,0102257	6,16256	0,0168863
Medidas de tendencia central						
Des. Estándar	1,268825933	0,00478382	1,234773602	0,005866653	1,006872982	0,006848923
Media	4,92995	0,011308929	5,29737	0,012552315	5,17987	0,012147898
Moda	4,33045	0,0119215	6,32911	NA	4,33045	NA
Moda	NA	NA	NA	NA	NA	NA

Anexo 4. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a limón, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

Sujeto	Manzana Fp1		Manzana Fp2		Manzana Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Sujeto1	5,49634	0,00771876	4,16389	0,0100446	5,49634	0,00580175
Sujeto2	4,49700	0,010262	4,497	0,0102733	4,497	0,0136644
Sujeto3	4,66356	0,0050616	5,66189	0,00478411	6,32911	0,0096934
Sujeto4	4,66356	0,0050616	3,99734	0,005452	6,32911	0,00884625
Sujeto5	4,497	0,00466965	3,99734	0,00592683	4,16389	0,0089364
Sujeto6	7,16189	0,00531966	3,99734	0,00565199	6,16256	0,0050649
Sujeto7	5,66289	0,0218381	5,66289	0,0313003	6,49567	0,0357544
Sujeto8	6,99534	0,00376037	4,66356	0,00406564	5,82945	0,00629618
Sujeto9	6,66223	0,0103811	5,32978	0,0148618	5,32978	0,00245775
Sujeto10	6,82878	0,00906274	5,82945	0,0124565	5,996	0,0145029

Medidas de tendencia central						
Varianza	1,110510078	0,005333572	0,765342108	0,008163148	0,796840775	0,009428052
Media	5,71286	0,008313558	4,78005	0,010481707	5,66289	0,011101833
Moda	4,497	0,0050616	3,99734	NA	6,32911	NA
Moda	4,66356	NA	NA	NA	NA	NA

Anexo 5. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a manzana, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

Sujeto	Menta Fp1		Menta Fp2		Menta Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Sujeto1	5,49634	0,0114521	4,497	0,011889	3,99734	0,0058662
Sujeto2	4,33045	0,00875408	4,33045	0,0142859	4,33045	0,0168882
Sujeto3	3,83078	0,00740784	5,66289	0,00612171	5,49634	0,0116279
Sujeto4	3,83078	0,00740784	4,33045	0,0119193	6,99534	0,00640871
Sujeto5	3,83078	0,0117341	5,66289	0,00843731	5,16322	0,00732857
Sujeto6	4,83011	0,0201094	5,82945	0,0138868	4,83011	0,0158063
Sujeto7	5,16322	0,0159427	6,99534	0,02331	6,32911	0,0230834
Sujeto8	5,16322	0,00370733	4,33045	0,0031981	4,83011	0,00594588
Sujeto9	4,33045	0,0149718	4,497	0,0146576	4,33045	0,00236881
Sujeto10	4,83011	0,0116488	6,16256	0,00680291	6,16256	0,00936081

Medidas de tendencia central						
Des. Estándar	0,619223587	0,004800484	0,955822488	0,005700856	0,98457348	0,006368262
Media	4,56362	0,011313599	5,22985	0,011450863	5,24650	0,010468478
Moda	3,83078	0,00740784	4,33045	NA	4,33045	NA
Moda	NA	NA	NA	NA	4,83011	NA

Anexo 6. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a menta, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

Sujeto	Naranja Fp1		Naranja Fp2		Naranja Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Sujeto1	4,49700	0,0148047	4,497	0,0129884	4,497	0,00336123
Sujeto2	5,32978	0,0110028	6,16256	0,0148689	5,32978	0,0150532
Sujeto3	4,16389	0,00696694	3,99734	0,00579244	4,16389	0,01059
Sujeto4	4,16389	0,00696694	6,32911	0,0056091	6,99534	0,00967378
Sujeto5	4,16389	0,0151736	4,83011	0,0168776	5,66289	0,0118135
Sujeto6	4,33045	0,0182106	4,16389	0,0335003	5,82945	0,028052
Sujeto7	5,32978	0,0131846	7,16189	0,0122322	5,82945	0,0186673
Sujeto8	3,99734	0,00453682	4,497	0,00279515	3,99734	0,00662244
Sujeto9	3,66422	0,00655099	4,16389	0,00800175	4,497	0,00274908
Sujeto10	3,99734	0,00822912	3,83078	0,00957391	6,49567	0,00501291

Medidas de tendencia central						
Des. Estándar	0,554073724	0,004576789	1,158728392	0,008697332	1,014639126	0,007815637
Media	4,36376	0,010562711	4,96336	0,012223975	5,32978	0,011159544
Moda	4,16389	0,00696694	4,497	NA	4,497	NA
Moda		NA	4,16389	NA	5,82945	NA

Anexo 7. Medidas de tendencia central durante OERP del ritmo Theta de olfacción a naranja, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

Sujeto	Trementina Fp1		Trementina Fp2		Trementina Fpz	
	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)	Frecuencia dominante (eje X) Hz	Densidad espectral de potencia (Eje Y) P1(f)
Sujeto1	5,16322	0,00901667	5,66289	0,00655912	3,99734	0,00852129
Sujeto2	5,99600	0,00593951	6,32911	0,00727847	5,16322	0,00756147
Sujeto3	6,99534	0,00550728	4,497	0,00532153	5,66289	0,00843784
Sujeto4	6,99534	0,00550728	3,99734	0,00428605	6,32911	0,007515
Sujeto5	4,16389	0,0116287	3,83078	0,00863992	4,33045	0,00973265
Sujeto6	6,99534	0,0253417	7,32845	0,0151863	6,99534	0,0125179
Sujeto7	6,16256	0,023015	6,32911	0,0278797	6,32911	0,0353226
Sujeto8	6,32911	0,00467401	3,83078	0,0047081	5,66289	0,00683188
Sujeto9	4,99667	0,0100737	3,99734	0,0136661	6,49567	0,00295975
Sujeto10	6,16256	0,00865207	4,83011	0,0131022	6,16256	0,0212528
Medidas de tendencia central						
Des. Estándar	0,955178754	0,007353528	1,264066999	0,007217961	0,964967994	0,009474915
Media	5,99600	0,010935592	5,06329	0,010662749	5,71286	0,012065318
Moda	6,99534	0,00550728	6,32911	NA	5,66289	NA
Moda		NA	3,99734	NA	6,32911	NA
Moda		NA	3,83078	NA	NA	NA

Anexo 8 Medidas de tendencia central durante OERP del ritmo Theta de olfacción a trementina, tomando como referencia en punto máximo de densidad espectral en la frecuencia dominante PSD correspondieres a Fp1, Fp2 y Fpz.

Bibliografía

- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M., Gertych, A., & Tan, R. S. (2017). A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine*, 89, 389–396. <https://doi.org/10.1016/j.combiomed.2017.08.022>
- Albaqami, H., Hassan, G. M., & Datta, A. (2023). Automatic Detection of Abnormal EEG Signals Using WaveNet and LSTM. *Sensors*, 23(13), 5960. <https://doi.org/10.3390/s23135960>
- Alfaro, L., Ballesteros, L., & Posada Mary. (2020). Alteraciones en el olfato y el gusto asociadas con la infección por SARS-CoV-2: una revisión. *Acta de Otorrinolaringología & Cirugía de Cabeza y Cuello*. [https://doi.org/10.37076/acorl.v48i4.56544\(2\)](https://doi.org/10.37076/acorl.v48i4.56544(2))
- Ali, M., Pandey, R. K., Khatoun, N., Narula, A., Mishra, A., & Prajapati, V. K. (2017). Exploring dengue genome to construct a multi-epitope based subunit vaccine by utilizing immunoinformatics approach to battle against dengue infection. *Scientific Reports*, 7(1). <https://doi.org/10.1038/s41598-017-09199-w>
- Aracena, C., Villena, F., Arias, F., & Dunstan, J. (2022). Applications of machine learning in healthcare. *Revista Medica Clinica Las Condes*, 33(6), 568–575. <https://doi.org/10.1016/j.rmcl.2022.10.001>
- Ávila-Tomás, J. F., Mayer-Pujadas, M. A., & Quesada-Varela, V. J. (2021). Artificial intelligence and its applications in medicine II: Current importance and practical applications. *Atencion Primaria*, 53(1), 81–88. <https://doi.org/10.1016/j.aprim.2020.04.014>

- Berkhin, P. (2006). *Grouping multidimensional data. Recent advances in clustering*.
- Bonfils, P. (2008). Fisiología, exploración y trastornos de la olfacción. *EMC-Otorrinolaringología*, 37. <https://www.sciencedirect.com/science/article/abs/pii/S1632347508703114>
- Bowers, A., Gore, J. C., Wexler, B. E., Fulbright, R. K., Skudlarski, P., Lacadie, C. M., Warrenburg, S., Fulbright, R. K., Skudlarski, P., Lacadie, C. M., Warrenburg, S., Bowers, A. A., Gore, J. C., & Wexler, B. E. (1998). responses to pleasant and unpleasant odors. Functional MR imaging of regional brain Functional MR Imaging of Regional Brain Responses to Pleasant and Unpleasant Odors. In *AJNR Am J Neuroradiol* (Vol. 19, Issue 9). <http://www.ajnr.org/content/19/9/>
- Carrillo, B., Carrillo A, V., Astorga, A., Hormachea, D., & Resumen, F. I. (2017). Diagnóstico en la patología del olfato: Revisión de la literatura Diagnosis in smell pathology: Literature review. In *Rev. Otorrinolaringol. Cir. Cabeza Cuello* (Vol. 77).
- Carrobes, J. A. (2016). Bio/neurofeedback. *Clinica y Salud*, 27(3), 125–131. <https://doi.org/10.1016/j.clysa.2016.09.003>
- Chacón Martínez, J., Morales Puebla, J. M., & Antolín, J. A. J. (2005). *PATOLOGÍA DE LA OLFACCIÓN. OLFATOMETRÍA. MANEJO DE LOS PROBLEMAS OLFATIVOS*.
- Chaná, P., & Júri, C. (2007). *Déficit de la olfacción en la enfermedad de Parkinson: Un síntoma a considerar en la práctica clínica*.
- Cofré, A., Ricciardi, D., & Soler, G. (2015). Alteraciones del olfato asociadas a hipogonadismo hipogonadotrófico. Su importancia en la detección precoz. *REVISTA FASO*.
- Daniel, L., Crusaley, R., Cárdenas-Valdez, J. R., Enrico Vázquez, G., De Jesús, M., Ortega, G., & Calvillo Téllez, A. (2019). Sistema de clasificación SVM de señales electromiográficas extraídas en un sistema embebido SVM Classification System of Electromyographic Signals Extracted in an Embedded System. In *Research in Computing Science* (Vol. 148, Issue 2).
- Ester, M., Kriegel, H.-P., Sander, J., & Xu, X. (1996). *A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise*. www.aaai.org
- Fernández, M. Á. G. (2019). Artificial intelligence in cardiac imaging: The future is here. *Revista Argentina de Cardiología*, 87(6), 469–473. <https://doi.org/10.7775/rac.v87.i6.16997>
- Fornazieri, M., de Rezende, F., & Pinto, T. (2010). Applicability of the university of pennsylvania smell identification test (SIT) in brazilians: pilot study. *Braz J Otorhinolaryngol*.
- Fulbright, R. K., Skudlarski, P., Lacadie, C. M., Warrenburg, S., Bowers, A. A., Gore, J. C., & Wexler, B. E. (1998). responses to pleasant and unpleasant odors. Functional MR imaging of regional brain Functional MR Imaging of Regional Brain Responses to Pleasant and Unpleasant Odors. In *AJNR Am J Neuroradiol* (Vol. 19, Issue 9). <http://www.ajnr.org/content/19/9/>
- Galván, P., Fusillo, J., González, F., Vukujevic, O., Recalde, L., Rivas, R., Ortellado, J., Portillo, J., Borba, J., & Hilario, E. (2022). Feasibility of using artificial intelligence for screening COVID-19 patients in Paraguay. *Revista Panamericana de Salud Publica/Pan American Journal of Public Health*, 46. <https://doi.org/10.26633/RPSP.2022.20>
- Gómez-Díaz, M., Villalobos-Torres, A., Lara-Rendón, C., Juárez-Guerra, L., Castellanos-Nolasco, E., Ortiz-Gaucín, A., & Suarez Y Gómez, L. (2018a). Análisis de bioseñales: Enfoque técnico de la adquisición, procesamiento y sus aplicaciones. *INNOVACIÓN Y DESARROLLO TECNOLÓGICO REVISTA DIGITAL*, 10(2).
- Gómez-Díaz, M., Villalobos-Torres, A., Lara-Rendón, C., Juárez-Guerra, L., Castellanos-Nolasco, E., Ortiz-Gaucín, A., & Suarez Y Gómez, L. (2018b). *INNOVACIÓN Y DESARROLLO TECNOLÓGICO REVISTA DIGITAL Análisis de bioseñales: Enfoque técnico de la adquisición, procesamiento y sus aplicaciones*. 10(2).
- Guerrero Martínez, J. F. (2010). *INGENIERÍA BIOMÉDICA Tema 2 Bioseñales 2.1. Introducción*.
- Guevara, G. L. (2016). *CLASIFICACION DE SEÑALES DE ELECTROENCEFALOGRAMA PARA DIAGNOSTICAR DEPRESION CLASSIFICATION OF EEG SIGNALS FOR DIAGNOSING DEPRESSION*.
- Han, J., Kamber, M., & Pei, J. (2011a). *Data Mining. Concepts and Techniques, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems)*.
- Han, J., Kamber, M., & Pei, J. (2011b). *Data Mining. Concepts and Techniques, 3rd Edition (The Morgan Kaufmann Series in Data Management Systems)*.
- Hou, H. R., Meng, Q. H., & Sun, B. (2022a). A triangular hashing learning approach for olfactory EEG signal recognition. *Applied Soft Computing*, 118. <https://doi.org/10.1016/j.asoc.2022.108471>
- Hou, H. R., Meng, Q. H., & Sun, B. (2022b). A triangular hashing learning approach for olfactory EEG signal recognition. *Applied Soft Computing*, 118. <https://doi.org/10.1016/j.asoc.2022.108471>
- Hummel, T., Kobal, G., Gudziol, H., & Mackay-Sim, A. (2007). Normative data for the “Sniffin” Sticks" including tests of odor identification, odor discrimination, and olfactory thresholds: An upgrade based on a group of

- more than 3,000 subjects.” *European Archives of Oto-Rhino-Laryngology*, 264(3), 237–243.
<https://doi.org/10.1007/s00405-006-0173-0>
- IBM. (2021a). *Conceptos básicos de ayuda de CRISP-DM*. <https://www.ibm.com/docs/es/spss-modeler/saas?topic=dm-crisp-help-overview>
- IBM. (2021b). *Conceptos básicos de ayuda de CRISP-DM*. <https://www.ibm.com/docs/es/spss-modeler/saas?topic=dm-crisp-help-overview>
- Iravani, B., Arshamian, A., Ohla, K., Wilson, D. A., & Lundström, J. N. (2020a). Non-invasive recording from the human olfactory bulb. *Nature Communications*, 11(1). <https://doi.org/10.1038/s41467-020-14520-9>
- Iravani, B., Arshamian, A., Ohla, K., Wilson, D. A., & Lundström, J. N. (2020b). Non-invasive recording from the human olfactory bulb. *Nature Communications*, 11(1). <https://doi.org/10.1038/s41467-020-14520-9>
- Iravani, B., Arshamian, A., Schaefer, M., Svenningsson, P., & Lundström, J. N. (2021). A non-invasive olfactory bulb measure dissociates Parkinson’s patients from healthy controls and discloses disease duration. *Npj Parkinson’s Disease*, 7(1). <https://doi.org/10.1038/s41531-021-00220-8>
- Izquierdo-Domínguez, A., Rojas-Lechuga, M. J., Mullol, J., & Alobid, I. (2020). Olfactory dysfunction during COVID-19 pandemic. *Medicina Clínica*, 155(9), 403–408. <https://doi.org/10.1016/j.medcli.2020.06.006>
- J. A. F. Tresguerres, Orlando A. Mora Novaro, & José E. Sánchez Criado. (2005). *Fisiología humana (3a. ed.)* (3a. ed).
- Jain, A. K., Murty, M. N., & Flynn, P. J. (2000). *Data Clustering: A Review*.
- Jorge Díaz-Ramírez. (2021). Aprendizaje Automático y Aprendizaje Profundo. *Ingeniare. Revista Chilena de Ingeniería*, 29(2), 182–183. <https://www.mckinsey.com/business-functions/sustainability/our-insights/artificial-intelligence-and-the->
- Jose, M., & Juan Ramirez. (2020). *Procesamiento Embebido de P300 Basado en Red Neuronal Convolutiva para Interfaz Cerebro-Computadora Ubicua*.
- Kamel, N., & Malik, A. S. (2015). *EEG/ERP analysis : methods and applications*.
- Klemm, W. R., Lutes, S. D., Hendrix, D. V., & Warrenburg, S. (1992). Topographical EEG maps of human responses to odors. In *Chemical Senses* (Vol. 17, Issue 3). <http://chemse.oxfordjournals.org/>
- Kobal, G., Klimek, L., Wolfensberger, M., & Gudziol, H. (2000). Multicenter investigation of 1,036 subjects using a standardized method for the assessment of olfactory function combining tests of odor identification, odor discrimination, and olfactory thresholds. *Eur Arch Otorhinolaryngol*.
- Krbot Skorić, M., Adamec, I., Jerbić, A. B., Gabelić, T., Hajnšek, S., & Habek, M. (2015a). Electroencephalographic Response to Different Odors in Healthy Individuals: A Promising Tool for Objective Assessment of Olfactory Disorders. *Clinical EEG and Neuroscience*, 46(4), 370–376. <https://doi.org/10.1177/1550059414545649>
- Krbot Skorić, M., Adamec, I., Jerbić, A. B., Gabelić, T., Hajnšek, S., & Habek, M. (2015b). Electroencephalographic Response to Different Odors in Healthy Individuals: A Promising Tool for Objective Assessment of Olfactory Disorders. *Clinical EEG and Neuroscience*, 46(4), 370–376. <https://doi.org/10.1177/1550059414545649>
- Lemuz-López, R., Gómez-López, W., Ayaquica-Martínez, I., & Guillén-Galván, C. (2014). *Selección de Electroodos Basada en k-means para la Clasificación de Actividad Motora en EEG*.
- Liu, B., Chang, H., Peng, K., & Wang, X. (2022). An End-to-End Depression Recognition Method Based on EEGNet. *Frontiers in Psychiatry*, 13. <https://doi.org/10.3389/fpsy.2022.864393>
- Loncaric, F., Camara, O., & Piella, G. (2021). La integración de la inteligencia artificial en el abordaje clínico del paciente: enfoque en la imagen cardiaca. *Revista Española de Cardiología*. <https://doi.org/.j.recesp...>
- Lorena, M., Javier, S., & Alberto Calderón, M. P. (2020). *Detección de patologías en señales biomédicas mediante técnicas de machine learning*.
- Lorig, T. S., & Schw Artz, G. E. (1988). Brain and odor: 1. Alteration of human EEG by odor administration. In *Psychobiology* /988 (Issue 3).
- Losada, D. (2020). *Caracterización de Potenciales EEG Olfativos en Personas Saludables*. Universidad Antonio Nariño.
- Lotte, F., Bougrain, L., Cichocki, A., Clerc, M., Congedo, M., Rakotomamonjy, A., & Yger, F. (2018). A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update. In *Journal of Neural Engineering* (Vol. 15, Issue 3). Institute of Physics Publishing. <https://doi.org/10.1088/1741-2552/aab2f2>
- Martin, G. N. (1998a). Human electroencephalographic (EEG) response to olfactory stimulation: Two experiments using the aroma of food. *International Journal of Psychophysiology*, 30(3), 287–302. [https://doi.org/10.1016/S0167-8760\(98\)00025-7](https://doi.org/10.1016/S0167-8760(98)00025-7)
- Martin, G. N. (1998b). Human electroencephalographic (EEG) response to olfactory stimulation: Two experiments using the aroma of food. *International Journal of Psychophysiology*, 30(3), 287–302. [https://doi.org/10.1016/S0167-8760\(98\)00025-7](https://doi.org/10.1016/S0167-8760(98)00025-7)

- Masaoka, Y., Harding, I. H., Koiwa, N., Yoshida, M., Harrison, B. J., Lorenzetti, V., Ida, M., Izumizaki, M., Pantelis, C., & Homma, I. (2014). The neural cascade of olfactory processing: A combined fMRI-EEG study. *Respiratory Physiology and Neurobiology*, 204, 71–77. <https://doi.org/10.1016/j.resp.2014.06.008>
- Mazzola, M. (2021). Aplicación de la Inteligencia Artificial Geoespacial a la epidemiología medio ambiental. *Universidad de Malaga*.
- Medina, A. (2015). *Diagnóstico de Señales Biomédicas con Redes Neuronales Artificiales*.
- Meza, B. (n.d.). *Clasificación de señales EMG*.
- Micó, P. (2005). *Nuevos desarrollos y aplicaciones basados en métodos estocásticos para el agrupamiento no supervisado de latidos en señales electrocardiográficas*.
- Mjahad, A. (2017). *Análisis de Señales Biomédicas para Aplicación de Terapias en la Fibrilación Ventricular Cardíaca*. www.who.int/mediacentre/factsheets/fs317/es/.
- Moein, S. T., Hashemian, S. M. R., Mansourafshar, B., Khorram-Tousi, A., Tabarsi, P., & Doty, R. L. (2020). Smell dysfunction: a biomarker for COVID-19. *International Forum of Allergy and Rhinology*, 10(8), 944–950. <https://doi.org/10.1002/alr.22587>
- Muñoz Gamboa, C., & Jiménez Cruz, J. (2008). *Potenciales evocados y cognición Artemisa medigraphic en línea* (Issue 1). www.medigraphic.com
- Najarian, K. S. (n.d.). *Biomedical Signal and Image Processing*.
- Namazi, H., Akrami, A., Nazeri, S., & Kulish, V. V. (2016). Analysis of the Influence of Complexity and Entropy of Odorant on Fractal Dynamics and Entropy of EEG Signal. In *BioMed Research International* (Vol. 2016). Hindawi Limited. <https://doi.org/10.1155/2016/5469587>
- Noelia, A., & Cicchino, B. (2013). *UNIVERSIDAD NACIONAL DE LA PLATA FACULTAD DE INGENIERÍA Tesis presentada para la obtención del grado de MAGISTER EN INGENIERÍA*.
- Organización Panamericana de la Salud. (2020). *La OMS caracteriza a COVID-19 como una pandemia*.
- Pablo Antonio Stack Sánchez. (2021). *Métodos de Aprendizaje Supervisado y no Supervisado para la Estimación de Microestructura Cerebral en Datos de DWMR*. Centro de Investigación en Matemáticas, A.C.
- Pause, B. M., Sojka, B., Krauel, K., & Ferstl, R. (1996). The nature of the late positive complex within the olfactory event-related potential (OERP). *Psychophysiology*, 33(4). <https://doi.org/10.1111/j.1469-8986.1996.tb01062.x>
- Quarmley, M., Moberg, P. J., Mechanic-Hamilton, D., Kabadi, S., Arnold, S. E., Wolk, D. A., & Roalf, D. R. (2017). Odor Identification Screening Improves Diagnostic Classification in Incipient Alzheimer's Disease. *Journal of Alzheimer's Disease*, 55(4), 1497–1507. <https://doi.org/10.3233/JAD-160842>
- Rahayel, S., Frasnelli, J., & Joubert, S. (2012a). The effect of Alzheimer's disease and Parkinson's disease on olfaction: A meta-analysis. *Behavioural Brain Research*, 231(1), 60–74. <https://doi.org/10.1016/j.bbr.2012.02.047>
- Rahayel, S., Frasnelli, J., & Joubert, S. (2012b). The effect of Alzheimer's disease and Parkinson's disease on olfaction: A meta-analysis. *Behavioural Brain Research*, 231(1), 60–74. <https://doi.org/10.1016/j.bbr.2012.02.047>
- Rand, W. M. (1971). Objective Criteria for the Evaluation of Clustering Methods. In *Source: Journal of the American Statistical Association* (Vol. 66, Issue 336).
- Rasheed, K., Qayyum, A., Qadir, J., Sivathamboo, S., Kwan, P., Kuhlmann, L., O'Brien, T., & Razi, A. (2020). *Machine Learning for Predicting Epileptic Seizures Using EEG Signals: A Review*. <http://arxiv.org/abs/2002.01925>
- Rasheed, M. A., Chand, P., Ahmed, S., Sharif, H., Hoodbhoy, Z., Siddiqui, A., & Hasan, B. S. (2021). Use of artificial intelligence on Electroencephalogram (EEG) waveforms to predict failure in early school grades in children from a rural cohort in Pakistan. *PLoS ONE*, 16(2 February). <https://doi.org/10.1371/journal.pone.0246236>
- Ribeiro, J. C., Simões, J., Silva, F., Silva, E. D., Hummel, C., Hummel, T., & Paiva, A. (2016). Cultural adaptation of the Portuguese version of the "Sniffin" Sticks" smell test: Reliability, validity, and normative data." *PLoS ONE*, 11(2). <https://doi.org/10.1371/journal.pone.0148937>
- Robles-Osorio, M. L., Corona, R., Morales, T., & Sabath, E. (2020). Enfermedad renal crónica y olfato. *Nefrología*, 40(2), 120–125. <https://doi.org/10.1016/j.nefro.2019.04.009>
- Sanei, S., & Chambers, J. A. (2007). *EEG SIGNAL PROCESSING*.
- Sarmiento, J. F. (2024). *Diagnostico diferencial de síndromes demenciales para el reconocimiento de Alzheimer en personas con déficit cognitivo leve: potenciales biomarcadores de señales EEG*. Open Science Framework OSF. https://osf.io/ed6kh/?view_only=5679a4a07d964e578065a221d2f548dc
- Schriever, V. A., Han, P., Weise, S., Hösel, F., Pellegrino, R., & Hummel, T. (2017). Time frequency analysis of olfactory induced EEG-power change. *PLoS ONE*, 12(10). <https://doi.org/10.1371/journal.pone.0185596>

- Singh, K. K. (Telecommunications professor), Elhoseny, M., Singh, A., & Elngar, A. A. (2021). *Machine learning and internet of medical things in healthcare*.
- Sowndhararajan, K., & Kim, S. (2016). Influence of fragrances on human psychophysiological activity: With special reference to human electroencephalographic response. In *Scientia Pharmaceutica* (Vol. 84, Issue 4, pp. 724–751). MDPI AG. <https://doi.org/10.3390/scipharm84040724>
- Stoica, Petre., & Moses, R. L. (2005). *Spectral analysis of signals*. Pearson/Prentice Hall.
- Subasi, A. (2019). Biomedical Signal Classification Methods. In *Practical Guide for Biomedical Signals Analysis Using Machine Learning Techniques* (pp. 277–434). Elsevier. <https://doi.org/10.1016/b978-0-12-817444-9.00005-2>
- Sudip, P. (2019). Biomedical engineering and its applications in healthcare. In *Biomedical Engineering and its Applications in Healthcare*. Springer Singapore. <https://doi.org/10.1007/978-981-13-3705-5>
- Sugawara, Y., Shigetho, A., Yoneda, M., Tuchiya, T., Yamada, H., Matumura, T., & Hirano, M. (2015). Relationship between Mood Change, Odor and Its Psychophysiological Responses in Humans in Terms of the Sensory Evaluation Spectrum. *Psychology*, 06(08), 965–988. <https://doi.org/10.4236/psych.2015.68095>
- Tompkins, W. J. (2000). *BIOMEDICAL DIGITAL SIGNAL PROCESSING C-Language Examples and Laboratory Experiments for the IBM® PC*.
- Tran, Y. (2020). *EEG Signal Processing for Biomedical Applications*. www.mdpi.com/journal/sensors
- Tresguerres. (2005). *Fisiologia humana (3a. ed.)*.
- Tyler S. Lorig. (1999). On the similarity of odor and language perception. *Neuroscience & Biobehavioral Reviews*, 23(3), 391–398.
- Vilela Junior, G. de B., Lima, B. N., Ribeiro, H. F., Rodrigues, M. F., Pereira, A. de A., Oliveira, J. R. L. de, Silio, L. F., & Passos, R. P. (2022). IMPORTÂNCIA DO ÍNDICE FOWLKES-MALLOWS (IMF), DO COEFICIENTE DE CORRELAÇÃO DE MATTHEWS (MCC) E DO ÍNDICE YOUDEN (IY) NOS CLASSIFICADORES DE INTELIGÊNCIA ARTIFICIAL NA ÁREA DA SAÚDE. *Centro de Pesquisas Avançadas Em Qualidade de Vida*, 14(v14n2), 1. <https://doi.org/10.36692/v14n3-01>
- Walla, P., Duregger, C., Deecke, L., & Dal-Bianco, P. (2011). Dysfunctional incidental olfaction in mild cognitive impairment (MCI): An electroencephalography (EEG) study. *Brain Sciences*, 1(1), 3–15. <https://doi.org/10.3390/brainsci1010003>
- Wen, J., Thibeau-Sutre, E., Diaz-Melo, M., Samper-González, J., Routier, A., Bottani, S., Dormont, D., Durrleman, S., Burgos, N., & Colliot, O. (2020). Convolutional neural networks for classification of Alzheimer’s disease: Overview and reproducible evaluation. *Medical Image Analysis*, 63. <https://doi.org/10.1016/j.media.2020.101694>
- Xing, M., Hu, S., Wei, B., & Lv, Z. (2022). Spatial-frequency-temporal convolutional recurrent network for olfactory-enhanced EEG emotion recognition. *Journal of Neuroscience Methods*, 376. <https://doi.org/10.1016/j.jneumeth.2022.109624>
- Xuan Vinh, N., Epps, J., Cameron Bailey, J., Vinh Edu Au, N. X., Julien Epps, U., U Au, U. E., & Bailey, J. (2010). Information Theoretic Measures for Clusterings Comparison: Variants, Properties, Normalization and Correction for Chance. In *Journal of Machine Learning Research* (Vol. 11). https://www.researchgate.net/publication/220320632_Information_Theoretic_Measures_for_Clusterings_Comparison_Variants_Properties_Normaliz
- Yavuz, E., & Aydemir, O. (2016, September 19). Olfaction recognition by EEG analysis using wavelet transform features. *Proceedings of the 2016 International Symposium on INnovations in Intelligent SysTems and Applications, INISTA 2016*. <https://doi.org/10.1109/INISTA.2016.7571827>
- Zgallai, W. A. (2020). *Biomedical signal processing and artificial intelligence in healthcare*.
- Zhang, X. N., Meng, Q. H., Zeng, M., & Hou, H. R. (2021). Decoding olfactory EEG signals for different odor stimuli identification using wavelet-spatial domain feature. *Journal of Neuroscience Methods*, 363. <https://doi.org/10.1016/j.jneumeth.2021.109355>