



UNIVERSIDAD DE VALLADOLID
E.T.S.I DE TELECOMUNICACIÓN

TRABAJO FINAL DE GRADO
GRADO EN INGENIERÍA DE TECNOLOGÍAS DE
TELECOMUNICACIÓN

Análisis de movimientos oculares en
experimentos de seguimiento visual.

Autor:
Jorge Ansótegui Gandul

Tutor:
Rodrigo de Luis García

17 de julio de 2025

Resumen

Este Trabajo de Fin de Grado aborda el análisis de movimientos oculares mediante técnicas de eye tracking, con el objetivo de explorar su utilidad como herramienta no invasiva en el estudio del comportamiento visual humano. Se diseñó un protocolo experimental compuesto por ocho tareas visuales que permitieron registrar la actividad oculomotora de 77 participantes. Tras un exhaustivo proceso de preprocesado y calibración de las señales, se extrajeron múltiples parámetros oculomotores, incluyendo medidas de sacadas, fijaciones, seguimiento suave y métricas de entropía. Posteriormente, se emplearon modelos de regresión para estimar la edad de los sujetos a partir de dichos parámetros. Aunque los resultados no mostraron una capacidad predictiva destacable ni correlaciones sólidas con la edad, el trabajo aporta una base metodológica sólida y destaca los retos asociados al análisis de datos oculomotores en contextos clínicos y computacionales. Se discuten las limitaciones encontradas y se proponen líneas futuras de mejora.

Palabras Clave: Seguimiento ocular, Parametrización, Movimientos oculares, Preprocesamiento de señales, Aprendizaje automático.

Abstract

This Bachelor's Thesis explores the analysis of eye movements using eye tracking technology, aiming to assess its potential as a non-invasive tool for studying human visual behavior. An experimental protocol consisting of eight visual tasks was designed to record oculomotor activity in 77 participants. After an extensive preprocessing and calibration pipeline, a wide range of oculomotor parameters were extracted, including measures of saccades, fixations, smooth pursuit, and entropy-based metrics. Regression models were subsequently applied to estimate participants' age based on these features. Although the results did not show strong predictive performance or robust correlations with age, the study provides a solid methodological framework and highlights the challenges involved in oculomotor data analysis for clinical and computational applications. Limitations are discussed, and future directions are proposed.

Keywords: Eye tracking, Parameterization, Ocular movements, Signal preprocessing, Machine learning.

Agradecimientos

A mi tutor Rodrigo de Luis García, por su guía durante el desarrollo del proyecto y por encargarse de la recogida de los datos experimentales, gran contribución para la realización de este trabajo. Su apoyo técnico ha sido clave en varias fases del proceso.

A todos los participantes voluntarios, por prestar su tiempo y colaboración de forma desinteresada. Su participación ha sido imprescindible para la obtención de los datos de este estudio.

A la Universidad de Valladolid, y en particular a la Escuela Técnica Superior de Ingenieros de Telecomunicación, por ofrecerme la formación, los recursos y el entorno académico necesarios para llevar a cabo este proyecto y completar mi etapa universitaria.

A mi familia, por su apoyo constante, su paciencia incondicional y por estar siempre presentes, especialmente en los momentos de mayor esfuerzo. Gracias por acompañarme en cada paso del camino y por creer en mí incluso cuando yo dudaba.

Este trabajo es el resultado de un proceso largo, exigente y a veces incierto, pero también lleno de aprendizajes. A todos los que, de una forma u otra, han formado parte de este recorrido, gracias.

ÍNDICE DE CONTENIDOS

Índice de Figuras	xi
Índice de Tablas	xv
1 Introducción	1
1.1 Motivación	1
1.2 Objetivos del Proyecto	2
1.3 Estructura del Documento	3
2 Revisión del Estado del arte y Fundamentos teóricos	5
2.1 Estado del Arte y Aplicaciones Médicas del Eye Tracking	6
2.1.1 Evolución histórica y fundamentos técnicos	7
2.1.2 Movimientos oculares: conceptos fundamentales	7
2.1.3 Aplicaciones médicas y biomarcadores oculomotores	8
2.1.4 Conclusión	8
2.2 Fundamentos físicos del <i>eye tracking</i> por infrarrojos	9
2.3 Parametrización, Procesamiento y Modelado de Datos de <i>Eye Tracking</i>	9
2.3.1 Preprocesamiento de señales oculomotoras	10
2.3.2 Extracción de características	10
2.3.3 Normalización y estandarización	10
2.3.4 Modelado y estimación de edad mediante <i>machine learning</i> . .	11
2.3.5 Justificación y desafíos actuales	11
3 Metodología	13
3.1 Metodología de adquisición de datos	13
3.1.1 Condiciones experimentales y equipamiento	13
3.1.2 Procedimiento con voluntarios	14

3.2	Descripción del conjunto de datos	14
3.2.1	Datos de los participantes	14
3.2.2	Estructura de los datos de seguimiento ocular	17
3.3	Descripción de los experimentos	18
3.3.1	Experimento 1: Fijación en puntos estáticos	18
3.3.2	Experimento 2: Seguimiento horizontal de un estímulo puntual	19
3.3.3	Experimento 3: Tarea de antisacadas	20
3.3.4	Experimento 4: Repetición del seguimiento horizontal	20
3.3.5	Experimento 5: Seguimiento de doble salto	21
3.3.6	Experimento 6: Seguimiento de trayectoria continua (<i>Lissajous</i>)	22
3.3.7	Experimento 7: Exploración libre de imágenes	22
3.3.8	Experimento 8: Tarea final de seguimiento horizontal	24
3.4	Preprocesado y calibración temporal de los datos	24
3.4.1	Arquitectura del sistema de procesamiento	24
3.4.2	Conversión y validación de formatos	25
3.4.2.1	Conversión JSON a formato MAT	25
3.4.2.2	Estructura de archivos	25
3.4.3	Filtrado de artefactos y preprocesamiento	25
3.4.3.1	Eliminación de parpadeos	25
3.4.3.2	Remuestreo de la señal	26
3.4.4	Sistema de calibración temporal adaptativo	27
3.4.4.1	Detección de fijaciones mediante clustering espacial .	27
3.4.4.2	Formación de super-clusters	27
3.4.4.3	Calibración temporal basada en sacadas	27
3.4.5	Calibración espacial	28
3.4.5.1	Calibración en el eje X (horizontal)	28
3.4.5.2	Calibración en el eje Y (vertical)	29
3.4.6	Procesamiento final y segmentación	30
3.4.6.1	Eliminación de transitorios	30
3.4.6.2	Segmentación por experimentos	30
3.4.7	Validación y control de calidad	31
3.4.8	Consideraciones técnicas	31
3.4.8.1	Robustez del algoritmo	31
3.4.8.2	Escalabilidad	31
3.5	Detección de fijaciones y sacadas	32
3.5.1	Fundamentos teóricos	32



3.5.2	Algoritmo de detección	32
3.5.2.1	Cálculo de velocidades	32
3.5.2.2	Clasificación basada en umbral de velocidad	33
3.5.2.3	Agrupación espacial y temporal	35
3.5.3	Refinamiento y optimización de parámetros	35
3.5.3.1	Combinación de clusters espacialmente próximos . .	35
3.5.3.2	Optimización automática de parámetros	35
3.5.4	Validación y control de calidad	36
3.5.5	Parámetros de salida	37
3.6	Parámetros oculomotores extraídos	37
3.6.1	Ganancia de sacadas (<i>Saccadic Gain</i>)	38
3.6.2	Sacadas correctivas (<i>Corrective Saccades</i>)	40
3.6.3	Coeficiente de anticipación y retraso	43
3.6.4	Coeficiente de antisacadas	45
3.6.5	Sacadas dobles (<i>Double Saccades</i>)	48
3.6.6	Seguimiento ocular suave (<i>Smooth Pursuit</i>)	50
3.6.7	Área envolvente convexa (<i>Convex Hull</i>)	52
3.6.8	Área Elíptica Bivariada de Contorno (<i>BCEA</i>)	55
3.6.9	Distancia cuadrática media al centro (<i>Root Mean Square Distance, RMS-dist</i>)	58
3.6.10	Entropía de Shannon espacial (<i>Shannon Entropy</i>)	61
3.6.11	Entropía de Muestra (<i>Sample Entropy</i>) del radio temporal .	64
3.7	Regression Learner: Plataforma de Entrenamiento y Optimización de Modelos	66
3.7.1	Arquitectura y Funcionalidades de Regression Learner . . .	67
3.7.1.1	Algoritmos Disponibles y Clasificación	67
3.7.2	Procedimientos de Entrenamiento y Validación	67
3.7.2.1	Partición de Datos y Validación Cruzada	67
3.7.2.2	Métricas de Evaluación	68
3.7.3	Optimización de Hiperparámetros	68
3.7.3.1	Búsqueda Bayesiana de Hiperparámetros	68
3.7.3.2	Hiperparámetros Críticos por Familia de Algoritmos	69
3.7.4	Estrategias de Optimización de Resultados	69
3.7.4.1	Preprocesamiento y Transformación de Características	69
3.7.4.2	Ensemble de Modelos	69
3.7.4.3	Validación y Diagnóstico de Modelos	70
3.7.5	Consideraciones Computacionales y Escalabilidad	70



4 Resultados y Discusión	71
4.1 Resultados	71
4.1.1 Correlaciones de los parámetros con la edad	71
4.1.2 Matriz de correlación entre parámetros oculomotores	76
4.1.3 Variabilidad Intra sujeto e Inter sujeto	81
4.1.4 Modelos de regresión para la predicción de la edad	84
4.1.5 Análisis de agrupamiento mediante <i>t-SNE</i>	88
4.2 Discusión de los resultados	89
5 Conclusiones y Lineas Futuro	91
Bibliografía	93



ÍNDICE DE FIGURAS

Figura 3.1 Distribución del genero de los participantes	15
Figura 3.2 Histograma de las edades de los participantes	16
Figura 3.3 Visualización del primer experimento: fijación en puntos estáticos. En la imagen se observa la trayectoria de la mirada del participante durante la primera ronda.	19
Figura 3.4 Visualización del segundo experimento: seguimiento horizontal de un estímulo puntual. En la imagen se observa la trayectoria de la mirada del participante durante la primera ronda.	19
Figura 3.5 Visualización del tercer experimento: tarea de antisacadas. En las imágenes se muestran las dos alternativas: primero aparece la flecha a la que los participantes no deben mirar; deben mirar al lado contrario para esperar a que aparezca el punto.	20
Figura 3.6 Visualización del cuarto experimento: seguimiento horizontal de un estímulo puntual. En la imagen se observa la trayectoria de la mirada del participante durante la primera ronda.	21
Figura 3.7 Visualización del quinto experimento: seguimiento de doble salto. En la imagen se observa la trayectoria que debería hacer el participante en color gris, y las líneas discontinuas proyectan el movimiento que realizan los puntos a una velocidad mucho más alta durante la primera ronda. Los números indican el orden en el que suceden los eventos.	21

Figura 3.8 Visualización del sexto experimento: seguimiento de trayectoria continua (<i>Lissajous</i>). En la imagen se observa la trayectoria de la mirada del participante durante las tres rondas. Cada ronda presenta una velocidad diferente del movimiento del punto, aumentando progresivamente. De más lenta a más rápida de izquierda a derecha.	22
Figura 3.9 Visualización del séptimo experimento: exploración libre de imágenes.	23
Figura 3.10 Visualización de la eliminación de los parpadeos.	26
Figura 3.11 Visualización de la calibración temporal. En este caso se retrasan todas las muestras de este caso unos 2.5 segundos para que coincidan con los tiempos objetivo de las sacadas.	28
Figura 3.12 Zona de calibración de la señal del eje X.	29
Figura 3.13 Calibración de la señal del eje Y.	29
Figura 3.14 Gráfica de los <i>cluster</i> agrupados de cada fijación. El ejemplo muestra el experimento que se usa para calibrar temporalmente todos los casos, además de para calibrar el propio <i>eye tracker</i>	33
Figura 3.15 Visualización de la velocidad entre muestras con el umbral de velocidad.	34
Figura 3.16 Visualización del histograma la velocidad.	34
Figura 3.17 Ejemplo de visualización de las ganancias de las sacadas calculadas para un participante.	40
Figura 3.18 Ejemplo de visualización de las trayectorias de <i>sacadas correctivas</i> detectadas sobre los <i>clusters</i> de fijación.	42
Figura 3.19 Ejemplo de visualización del <i>coeficiente de anticipación y retraso</i> frente a los estímulos visuales.	45
Figura 3.20 Ejemplo representativo de trayectorias oculares en la tarea de <i>antisacadas</i>	47
Figura 3.21 Ejemplo de visualización de una secuencia de <i>sacadas dobles</i> . En este caso, no se ha conseguido detectar la fijación previa por su brevedad (25 ms).	50
Figura 3.22 Ejemplo de visualización del área envolvente convexa (<i>convex hull</i>) superpuesta a los puntos de fijación ocular.	54
Figura 3.23 Ejemplo de visualización de la elipse de dispersión (<i>BCEA</i>) superpuesta a las posiciones oculares durante la fijación.	57
Figura 3.24 Ejemplo de visualización de la distribución de fijaciones, baricentro y círculo de radio <i>RMS-dist</i>	60



Figura 3.25 Ejemplo de visualización del mapa de calor y valor de <i>entropía de Shannon</i> espacial para un conjunto de fijaciones oculares.	63
Figura 3.26 Ejemplo de visualización de la serie temporal del radio y el valor de <i>Sample Entropy</i> calculado para un período de fijación.	66
Figura 4.1 Relación entre la Velocidad de Fijaciones (Exp. 2) y la edad.	71
Figura 4.2 Relación entre la Entropía de Muestra (Exp. 7) y la edad.	72
Figura 4.3 Visualización de la correlación de Pearson entre todos los parámetros, primer cuadrante.	77
Figura 4.4 Visualización de la correlación de Pearson entre todos los parámetros, segundo cuadrante.	77
Figura 4.5 Visualización de la correlación de Pearson entre todos los parámetros, tercer cuadrante.	78
Figura 4.6 Visualización de la correlación de Pearson entre todos los parámetros, cuarto cuadrante.	78
Figura 4.7 Ejemplo de variabilidad intra e inter sujeto para el parámetro <i>fijaciones_numero</i> en el Experimento 2.	81
Figura 4.8 Ejemplo de variabilidad intra e inter sujeto para el parámetro <i>coef_unificado_retraso</i> en el Experimento 8.	82
Figura 4.9 Comparativa de <i>RMSE</i> en validación y test para los diferentes modelos.	85
Figura 4.10 Comparativa de R^2 en validación y test para los diferentes modelos.	86
Figura 4.11 Gráficos de valores predichos frente a reales para los modelos seleccionados del modelo <i>Stepwise Linear Regresion</i>	86
Figura 4.12 Gráficos de valores predichos frente a reales para los modelos seleccionados del modelo <i>Medium Tree</i>	87
Figura 4.13 Gráficos de valores predichos frente a reales para los modelos seleccionados del modelo <i>Boosted Tree</i>	87
Figura 4.14 Análisis de agrupamiento mediante t-SNE. Cada punto representa un participante, coloreado según el grupo de edad (jóvenes y mayores).	88



ÍNDICE DE TABLAS

Tabla 3.1 Descripción de las variables clínicas recogidas por participante	17
Tabla 3.2 Cada imagen se mostró durante aproximadamente 7 segundos, intercaladas por puntos de transición centrales de 1 segundo para recenterar la mirada entre estímulos.	23
Tabla 4.1 Correlaciones de los parámetros Ganancia de Sacadas, Sacadas Correctivas, Coeficiente de Anticipación, Coeficiente de Retraso y Antisacadas. Valores de r y p para cada ronda R y tamaño de muestra N	73
Tabla 4.2 Correlaciones de los parámetros Envolvente Convexa, Distancia RMS, Área Elíptica Bivariada 68 % y del 95 %, Entropía de Shannon y de Muestra. Valores de r y p para cada ronda R y tamaño de muestra N	74
Tabla 4.3 Correlaciones de los parámetros Smooth Pursuit: Velocidades, Errores de Seguimiento y Duraciones de Pursuit; Velocidades y número de fijaciones. Valores de r y p para cada ronda R y tamaño de muestra N	75
Tabla 4.4 Principales correlaciones entre parámetros ($ r > 0,9$).	76
Tabla 4.5 Número asociado a cada parámetro en el mapa de correlación. . . .	79
Tabla 4.6 Número asociado a cada parámetro en el mapa de correlación. . . .	80
Tabla 4.7 Coeficiente de variación (CV) intra sujeto e inter sujeto para los principales parámetros y experimentos.	83
Tabla 4.8 Resultados de los modelos de regresión entrenados.	84

CAPÍTULO **1**

INTRODUCCIÓN

↑

1.1	Motivación	1
1.2	Objetivos del Proyecto	2
1.3	Estructura del Documento	3

1.1 Motivación

El presente proyecto surge a partir de la necesidad de analizar datos obtenidos mediante un *eye tracker*, un dispositivo de seguimiento ocular que permite registrar los movimientos oculares de los participantes en un experimento. La motivación principal detrás de este estudio radica en la posibilidad de utilizar estos datos en la identificación de patrones que podrían ser relevantes en la detección de diversas patologías neurológicas o cognitivas.

El *eye-tracking* es una tecnología que permite detectar y registrar, de forma precisa y objetiva, los movimientos oculares de una persona mientras realiza una tarea determinada. Mediante el uso de cámaras y sensores especializados, es posible conocer en todo momento hacia dónde dirige la mirada un individuo, cuánto tiempo fija la vista en un punto concreto, o cómo explora visualmente una escena. Esta información resulta de gran valor para comprender cómo las personas procesan la información visual y toman decisiones en función de lo que ven.

Las aplicaciones del *eye-tracking* son muy diversas y abarcan múltiples campos. En el ámbito de los videojuegos, se utiliza para mejorar la experiencia de usuario y desarrollar nuevas formas de interacción basadas en la mirada. En marketing y diseño web, permite analizar cómo los usuarios observan anuncios, páginas web o productos, optimizando así la disposición de los elementos visuales para captar mejor la atención. Además, el *eye-tracking* es fundamental en el desarrollo de sistemas de comunicación alternativa para personas con

discapacidades motoras o del habla, permitiendo que puedan interactuar con ordenadores y otros dispositivos únicamente con los ojos.

Desde una perspectiva científica, el *eye-tracking* es una herramienta esencial en psicología y neurociencia, ya que el sistema visual constituye una ventana privilegiada para estudiar el funcionamiento del cerebro. Analizando los patrones de movimiento ocular, es posible inferir procesos cognitivos, emocionales y atencionales, así como detectar alteraciones asociadas a diversas patologías neurológicas o psiquiátricas. El estudio de la mirada permite, por ejemplo, investigar cómo se distribuye la atención, cómo se procesa la información visual o cómo cambian estos procesos con la edad o en presencia de enfermedades.

En este contexto, el objetivo de este proyecto es extraer información relevante de los datos de *eye-tracking* obtenidos de un conjunto de sujetos sanos mientras realizan experimentos visuales sencillos. Se pretende analizar estos datos para identificar patrones y características que describan el comportamiento visual de los participantes y, entre otras cosas, explorar si esta información permite predecir variables de interés desde un punto de vista médico, como puede ser la edad de los sujetos. La hipótesis es que ciertos parámetros derivados de las señales de *eye-tracking* pueden reflejar cambios sutiles en el funcionamiento cerebral asociados al envejecimiento, lo que podría abrir la puerta al desarrollo de biomarcadores no invasivos para el estudio de la salud cerebral.

En definitiva, la motivación de este trabajo reside en explorar el potencial del *eye-tracking* como herramienta para el análisis del comportamiento visual humano y su posible utilidad en el ámbito médico, contribuyendo así al avance del conocimiento en la intersección entre tecnología, neurociencia y salud.

1.2 Objetivos del Proyecto

Los objetivos principales de este trabajo se resumen en los siguientes puntos:

- **Diseñar e implementar un flujo de preprocessado de los datos de *eye-tracking*** para solucionar problemas habituales como la sincronización temporal imperfecta, la presencia de parpadeos y otros artefactos que puedan afectar a la calidad de las señales registradas.
- **Extraer parámetros de interés de las señales de *eye-tracking*** que describan características relevantes del procesamiento visual de los sujetos, tales como la duración y frecuencia de las fijaciones, la amplitud y velocidad de los movimientos sacádicos, o la exploración espacial de los estímulos.
- **Explorar la posibilidad de predecir la edad de los sujetos** a partir de los parámetros extraídos de las señales de *eye-tracking*, evaluando el potencial de es-



tos indicadores como biomarcadores no invasivos de procesos relacionados con el envejecimiento cerebral.

Estos objetivos están orientados a sentar las bases para el uso del *eye-tracking* como herramienta de análisis del comportamiento visual humano y su posible aplicación en el ámbito médico, proporcionando metodologías y resultados que puedan ser útiles para futuras investigaciones en neurociencia, psicología y diagnóstico clínico.

1.3 Estructura del Documento

Este documento se organiza en los siguientes capítulos, siguiendo una estructura lógica y coherente con el desarrollo del trabajo:

- **Capítulo 1: Introducción**

Presenta la motivación, los objetivos y una visión general del proyecto.

- **Capítulo 2: Estado del arte**

Revisión de investigaciones previas, tecnologías y herramientas existentes relacionadas con el *eye-tracking* y su aplicación en neurociencia y análisis del comportamiento visual.

- **Capítulo 3: Metodología**

Descripción detallada de los métodos empleados para el preprocesado de datos, la extracción de parámetros y los enfoques utilizados para el análisis y la predicción.

- **Capítulo 4: Resultados y Discusión de los Resultados**

Presentación de los resultados obtenidos a partir del análisis de los datos y la evaluación de los modelos desarrollados. Interpretación y análisis crítico de los resultados, así como comparación con trabajos previos y discusión de las limitaciones del estudio.

- **Capítulo 5: Conclusiones**

Resumen de los principales hallazgos, conclusiones del trabajo y propuestas para líneas futuras de investigación.

Esta estructura facilita la comprensión global del proyecto, guiando al lector desde la motivación inicial hasta las conclusiones y posibles desarrollos futuros.



CAPÍTULO 2

REVISIÓN DEL ESTADO DEL ARTE Y FUNDAMENTOS TEÓRICOS

↑

2.1	Estado del Arte y Aplicaciones Médicas del Eye Tracking	6
2.2	Fundamentos físicos del <i>eye tracking</i> por infrarrojos	9
2.3	Parametrización, Procesamiento y Modelado de Datos de <i>Eye Tracking</i> . .	9

El eye tracking o seguimiento ocular ha experimentado una evolución significativa desde sus primeras aplicaciones experimentales hasta convertirse en una herramienta fundamental en diversas disciplinas científicas y aplicadas. Esta tecnología, que permite la medición precisa de los movimientos oculares y la dirección de la mirada, ha demostrado un potencial considerable en el ámbito biomédico, particularmente en la caracterización de patrones oculomotores asociados con el envejecimiento y diversas condiciones neurológicas.

La relevancia del eye tracking en aplicaciones médicas se fundamenta en la estrecha relación entre el sistema oculomotor y el funcionamiento del sistema nervioso central. Los movimientos oculares constituyen una ventana única hacia los procesos neurológicos subyacentes, proporcionando información valiosa sobre la integridad funcional de múltiples estructuras cerebrales. Esta característica hace del eye tracking una herramienta prometedora para el desarrollo de biomarcadores no invasivos que puedan contribuir tanto a la estimación de la edad biológica como a la detección temprana de patologías neurodegenerativas.

El presente capítulo tiene como objetivo proporcionar una revisión exhaustiva del estado actual del conocimiento en el campo del eye tracking aplicado a la medicina, con especial énfasis en su potencial para la estimación de edad y detección de patologías. Se abordará la evolución histórica y tecnológica de los sistemas de eye tracking, desde los primeros dispositivos mecánicos hasta las sofisticadas tecnologías actuales basadas en infrarrojos.

Asimismo, se analizarán los fundamentos técnicos que sustentan el funcionamiento de estos sistemas, incluyendo los principios físicos de detección y seguimiento ocular, los algoritmos de procesamiento de datos y las principales fuentes de error que pueden afectar la precisión de las mediciones.

Un componente esencial de este capítulo se centra en la revisión de las aplicaciones médicas del eye tracking, examinando los antecedentes en la detección de patologías neurológicas, los biomarcadores oculomotores establecidos y los desafíos actuales en la validación clínica. Se prestará especial atención a los parámetros oculomotores que han demostrado sensibilidad a los procesos de envejecimiento y a diversas condiciones patológicas, proporcionando la base teórica para la metodología propuesta en este trabajo.

La parametrización y procesamiento de datos de eye tracking representan aspectos técnicos críticos que determinan la calidad y utilidad de la información extraída. Por ello, se abordarán las técnicas de preprocessamiento de señales oculomotoras, los métodos de extracción de características y los enfoques de normalización y estandarización necesarios para el análisis comparativo entre individuos y poblaciones.

Finalmente, se examinará el estado del arte en la aplicación de técnicas de machine learning para la estimación de edad biológica y detección de patologías mediante eye tracking. Esta revisión incluirá una evaluación crítica de los enfoques metodológicos actuales, sus limitaciones y las oportunidades que presenta la integración de datos oculomotores con algoritmos de aprendizaje automático avanzados.

El análisis conjunto de estos elementos proporcionará el marco teórico y metodológico necesario para justificar y contextualizar la investigación desarrollada, estableciendo las bases para una comprensión integral de las posibilidades y limitaciones del eye tracking como herramienta de evaluación biomédica no invasiva.

2.1 Estado del Arte y Aplicaciones Médicas del Eye Tracking

El *eye tracking* o seguimiento ocular ha evolucionado desde sus primeras aplicaciones experimentales a finales del siglo XIX hasta convertirse en una herramienta fundamental en neurociencia, psicología y medicina [11]. Esta tecnología permite registrar y analizar con precisión los movimientos oculares, proporcionando información valiosa sobre los procesos cognitivos y el funcionamiento del sistema nervioso central.



2.1.1 Evolución histórica y fundamentos técnicos

Los primeros dispositivos de *eye tracking*, como el desarrollado por Huey en 1908, eran mecánicos y rudimentarios [11]. El avance hacia sistemas basados en vídeo y, posteriormente, en infrarrojos, permitió mejorar la precisión y reducir la invasividad, facilitando su uso en investigación clínica y biomédica.

Actualmente, la mayoría de los sistemas emplean el método de reflexión corneal y centro pupilar (*Pupil Center Corneal Reflection, PCCR*), que utiliza iluminación infrarroja y algoritmos de procesamiento de imagen para localizar el centro de la pupila y el reflejo corneal (*glint*) [11]. Los dispositivos pueden ser de sobremesa, portátiles o montados en cabeza, y alcanzan frecuencias de muestreo de hasta 2000 Hz, con precisiones de 0.1-0.5 grados de ángulo visual.

Las tendencias actuales se centran en la miniaturización, la integración con técnicas de *machine learning* y la aplicación en entornos clínicos y de salud digital [22, 43]. El desarrollo de sistemas accesibles y robustos está impulsando la adopción del *eye tracking* en la práctica clínica rutinaria.

2.1.2 Movimientos oculares: conceptos fundamentales

El análisis de los movimientos oculares se basa en la identificación de varios tipos de eventos:

- **Sacada (*saccade*):** Movimiento ocular rápido y balístico que desplaza la mirada de un punto a otro. Es el tipo de movimiento más frecuente durante la exploración visual y la lectura [36].
- **Antisacada (*antisaccade*):** Sacada voluntaria en dirección opuesta a un estímulo presentado, utilizada para evaluar el control inhibitorio y la función ejecutiva [31, 9].
- **Seguimiento suave (*smooth pursuit*):** Movimiento lento y continuo que permite seguir objetos en movimiento, reflejando la integridad de los circuitos cortico-subcorticales [4].
- **Fijación (*fixation*):** Periodo en el que la mirada permanece estable sobre un punto, permitiendo la adquisición de información visual detallada. Durante la fijación pueden producirse *microsacadas*, pequeños movimientos involuntarios que estabilizan la imagen [28].

Otros conceptos relevantes incluyen la *latencia de sacada* (tiempo entre el estímulo y el inicio del movimiento), la *ganancia de sacada* (relación entre la amplitud ejecutada y



la requerida) y la *precisión espacial* (exactitud con la que se alcanza el objetivo visual) [25, 12].

2.1.3 Aplicaciones médicas y biomarcadores oculomotores

El *eye tracking* se ha consolidado como una herramienta no invasiva para la detección y caracterización de patologías neurológicas y psiquiátricas [1, 27]. Los movimientos oculares constituyen biomarcadores sensibles de alteraciones en el sistema nervioso central, permitiendo la identificación temprana de enfermedades como el Parkinson, el Alzheimer y los trastornos del espectro autista (TEA).

En la enfermedad de Parkinson, se observan alteraciones en la velocidad y precisión de las sacadas y el seguimiento suave, incluso en fases iniciales [27]. En el Alzheimer, parámetros como el error absoluto de fijación y la tasa de errores en tareas de antisacadas han demostrado ser indicadores tempranos de deterioro cognitivo [30, 9]. En el caso de los TEA, el análisis de los *scanpaths* y el control inhibitorio mediante tareas de antisacadas permite diferenciar a individuos con alta precisión [14, 7].

Los principales biomarcadores oculomotores incluyen:

- **Latencia y ganancia de sacada:** Sensibles a alteraciones neurológicas y al envejecimiento [12, 21].
- **Tasa de errores de antisacadas:** Indicador de control inhibitorio y deterioro cognitivo [9, 31].
- **Suavidad del seguimiento:** Refleja la integridad de los circuitos motores y cognitivos [4].
- **Patrones de fijación y microsacadas:** Asociados a control motor fino y alteraciones cognitivas [28].

La integración de técnicas de *machine learning* ha permitido mejorar la clasificación automática de poblaciones clínicas a partir de parámetros oculomotores, abriendo nuevas posibilidades para el desarrollo de biomarcadores objetivos y personalizados [43, 7].

2.1.4 Conclusión

El avance del *eye tracking* ha permitido no solo una mejor comprensión de los procesos visuales y cognitivos, sino también el desarrollo de herramientas diagnósticas innovadoras en medicina. La definición precisa de los movimientos oculares y la identificación de biomarcadores robustos constituyen la base para su aplicación clínica y la integración con tecnologías emergentes como el *machine learning*.



2.2 Fundamentos físicos del *eye tracking* por infrarrojos

Los sistemas modernos de *eye tracking* se basan en principios ópticos que permiten la detección precisa y el seguimiento continuo de los movimientos oculares. El uso de luz infrarroja cercana constituye el elemento central de estos sistemas, ya que proporciona una fuente de iluminación estable y no visible para el usuario, evitando distracciones y permitiendo la obtención de imágenes de alta calidad independientemente de las condiciones de luz ambiental [11].

La luz infrarroja se dirige hacia los ojos, generando reflejos característicos tanto en la pupila como en la córnea. La pupila, al ser una estructura no reflectante, aparece oscura en las imágenes capturadas, mientras que el reflejo corneal (*glint*) se manifiesta como un punto brillante y bien definido. Esta diferencia de contraste facilita la localización automática del centro pupilar y del *glint* mediante algoritmos de procesamiento de imagen [11].

El método más extendido en la actualidad es la reflexión corneal y centro pupilar (*Pupil Center Corneal Reflection, PCCR*), que utiliza la posición relativa entre el centro de la pupila y el reflejo corneal para calcular la dirección de la mirada. Cuando el ojo rota, la posición del centro pupilar cambia respecto al *glint*, permitiendo así estimar con precisión el ángulo de la mirada [11].

La configuración típica de los sistemas de *eye tracking* incluye una o varias fuentes de luz infrarroja dispuestas alrededor de la cámara, lo que garantiza una iluminación uniforme y minimiza las sombras o artefactos que puedan interferir con la detección de las estructuras oculares. Esta disposición mejora la robustez y la precisión del sistema, permitiendo registrar movimientos oculares incluso en condiciones ambientales variables [11].

En resumen, los fundamentos físicos del *eye tracking* por infrarrojos se apoyan en la interacción diferencial de la luz infrarroja con las estructuras oculares y en la utilización de algoritmos avanzados de procesamiento de imagen para identificar y seguir con precisión los movimientos de

2.3 Parametrización, Procesamiento y Modelado de Datos de *Eye Tracking*

El procesamiento y análisis de datos de *eye tracking* constituye una etapa esencial para la extracción de información relevante en aplicaciones biomédicas. La calidad de los resultados



depende en gran medida de la robustez de las técnicas de preprocesamiento, la selección adecuada de características y la correcta normalización de los parámetros oculomotores.

2.3.1 Preprocesamiento de señales oculomotoras

El preprocesamiento de las señales de *eye tracking* es fundamental para garantizar la validez de los análisis posteriores. Esta etapa incluye la limpieza de la señal, la eliminación de ruido y la corrección de artefactos como parpadeos o pérdidas momentáneas de seguimiento. Además, algoritmos adaptativos permiten ajustar dinámicamente los parámetros de filtrado según las características de la señal, preservando eventos transitorios como las sacadas [29]. La detección y corrección de artefactos, como los producidos por movimientos de cabeza o cambios en la iluminación, se realiza mediante técnicas de interpolación y métodos automáticos de identificación de períodos de fijación estable [18]. La gestión adecuada de los parpadeos es especialmente relevante, ya que estos pueden generar interrupciones en la señal que deben ser identificadas y tratadas para evitar errores en la segmentación de eventos oculomotores [16].

2.3.2 Extracción de características

La extracción de características transforma las señales oculomotoras en parámetros cuantitativos que describen el comportamiento visual. Entre las métricas más relevantes se encuentran las temporales, como la latencia de sacada, la duración de fijaciones y la frecuencia de parpadeo, que han demostrado sensibilidad a factores como la edad y el estado cognitivo [21, 35]. La ganancia de sacada, definida como la relación entre la amplitud ejecutada y la requerida, es un indicador clave de la programación motora oculomotora [25]. Las métricas espaciales, como la precisión de fijación y la variabilidad de las sacadas, permiten evaluar la integridad del sistema oculomotor y detectar posibles alteraciones neurológicas [1]. Además, parámetros estadísticos como la desviación estándar de la latencia o la distribución de amplitudes de sacada aportan información sobre la consistencia y variabilidad del comportamiento visual [10, 3]. Características de orden superior, como la entropía o la complejidad temporal de las trayectorias oculares, se utilizan para capturar patrones sutiles y complejos del control visual [12, 28].

2.3.3 Normalización y estandarización

La normalización de los parámetros oculomotores es imprescindible para comparar resultados entre individuos y poblaciones. Las diferencias inter-individuales pueden deberse a factores fisiológicos, anatómicos o demográficos, por lo que es habitual emplear técnicas de



estandarización como la transformación *z-score* o la utilización de percentiles [37]. La edad es uno de los factores que más influye en los movimientos oculares, observándose tendencias sistemáticas en parámetros como la latencia y la ganancia de sacada a lo largo del ciclo vital [21, 35]. Por ello, es recomendable considerar la edad y otras variables relevantes en la interpretación de los resultados y en el desarrollo de modelos predictivos.

2.3.4 Modelado y estimación de edad mediante *machine learning*

El uso de técnicas de *machine learning* ha permitido avanzar en la estimación de la edad biológica a partir de parámetros oculomotores, integrando múltiples características y capturando relaciones complejas entre ellas [22, 29]. Los modelos actuales, basados en algoritmos supervisados y no supervisados, han demostrado capacidad para predecir la edad cronológica con errores medios absolutos bajos en poblaciones sanas [21, 24]. La combinación de *eye tracking* y *machine learning* ofrece ventajas como la no invasividad, la reproducibilidad y la sensibilidad a cambios sutiles en el sistema nervioso central.

2.3.5 Justificación y desafíos actuales

El enfoque basado en la parametrización avanzada y el modelado mediante *machine learning* se justifica por la necesidad de biomarcadores objetivos, accesibles y sensibles para la estimación de la edad biológica. Sin embargo, persisten desafíos como la necesidad de bases de datos amplias y representativas, la estandarización de protocolos y la consideración de la variabilidad individual [3, 10]. El desarrollo de metodologías robustas y la integración de nuevas fuentes de información continúan siendo áreas activas de investigación en el campo.



CAPÍTULO 3

METODOLOGÍA

↑

3.1	Metodología de adquisición de datos	13
3.2	Descripción del conjunto de datos	14
3.3	Descripción de los experimentos	18
3.4	Preprocesado y calibración temporal de los datos	24
3.5	Detección de fijaciones y sacadas	32
3.6	Parámetros oculomotores extraídos	37
3.7	Regression Learner: Plataforma de Entrenamiento y Optimización de Modelos	66

3.1 Metodología de adquisición de datos

La calidad y validez de los estudios de *eye tracking* dependen en gran medida de una metodología de adquisición de datos rigurosa y estandarizada [11, 37, 29]. En este trabajo, se han seguido recomendaciones ampliamente aceptadas para asegurar la reproducibilidad y la fiabilidad de los resultados. En este trabajo, la adquisición de los datos fue llevada a cabo por el tutor Rodrigo de Luis García, siguiendo recomendaciones ampliamente aceptadas para asegurar la reproducibilidad y la fiabilidad de los resultados.

3.1.1 Condiciones experimentales y equipamiento

Las sesiones se realizaron en un entorno controlado, con condiciones constantes de iluminación y mínima distracción visual o auditiva, siguiendo las directrices metodológicas para minimizar fuentes de error y maximizar la precisión de las mediciones [11, 37]. Se empleó un sistema de *eye tracking* de sobremesa con frecuencia de muestreo de 1000 Hz y precisión espacial típica de 0.3–0.5 grados de ángulo visual, montado sobre un monitor. La distancia

entre participante y pantalla ronda los 65 cm, pero no se ajusta con ningun procedimineto extra.

El sistema utiliza iluminación infrarroja de espectro cercano, no molesta para los participantes, y permite la captura precisa de movimientos oculares rápidos como las sacadas. La sincronización temporal entre la presentación de estímulos y la adquisición de datos se realiza mediante marcadores temporales (*timestamps*) de alta precisión, lo que facilita la alineación exacta entre eventos experimentales y respuestas oculomotoras [29].

3.1.2 Procedimiento con voluntarios

El reclutamiento de participantes y la gestión de las sesiones experimentales se realizaron conforme a los principios éticos de la Declaración de Helsinki. Los participantes recibieron información detallada sobre los objetivos y procedimientos del estudio.

Se aplicaron criterios de inclusión y exclusión para garantizar la calidad de los datos. Antes de cada sesión, se realizó una fase de familiarización y una calibración multipunto (9 puntos), repitiéndose si era necesario hasta alcanzar una precisión aceptable. Se incluyeron validaciones intermedias y pausas programadas para minimizar la fatiga y controlar posibles derivas de calibración (*calibration drift*) [11].

Durante la sesión, se registraron datos demográficos relevantes (edad, sexo, condiciones visuales) y se monitorizó el bienestar del participante, con la posibilidad de suspender la sesión en caso de incomodidad. La duración total de cada sesión se mantuvo dentro de límites razonables para evitar fatiga excesiva.

3.2 Descripción del conjunto de datos

En esta sección se describen las características del conjunto de datos utilizado para el análisis de la conducta oculomotora de los participantes. Por un lado, se presenta la información sociodemográfica y de condiciones visuales de los voluntarios, recogida en un fichero de tipo Excel. Por otro lado, se detalla la estructura de los datos generados por el sistema de seguimiento ocular (eye tracker) durante las sesiones de adquisición.

3.2.1 Datos de los participantes

El estudio se ha llevado a cabo con un total de 77 casos. La información recopilada para cada sujeto incluye los siguientes campos: identificador del caso, fecha de adquisición, sexo, edad, uso de gafas, uso de lentillas y presencia de alguna patología.



Los valores del sexo se codifican como V para varones y M para mujeres. Las variables **gafas**, **lentillas** y **patología** son binarias, donde el valor 1 indica la presencia de la condición correspondiente, y 0 su ausencia. Las edades de los voluntarios abarcan un amplio rango, desde los 19 hasta los 74 años, lo que permite considerar cierta variabilidad interindividual en el análisis oculomotor.

Cabe destacar que no todos los registros están completos; algunos casos recientes (por ejemplo, **caso040** a **caso052**) presentan información parcialmente ausente, lo que ha sido tenido en cuenta en el preprocesamiento de los datos.

Información general del estudio

El conjunto de datos fue recopilado con el objetivo de analizar la conducta oculomotora mediante la creación de parámetros descriptores de los movimientos oculares. La recolección de datos se llevó a cabo utilizando tecnología de seguimiento ocular durante un período comprendido entre octubre de 2021 y enero de 2025.

Características de la muestra

- **Total de participantes:** 77 voluntarios.
- **Período de recolección:** Octubre de 2021 a enero de 2025.

Distribución por sexo:

- Mujeres (M): 38 participantes
- Hombres (V): 39 participantes

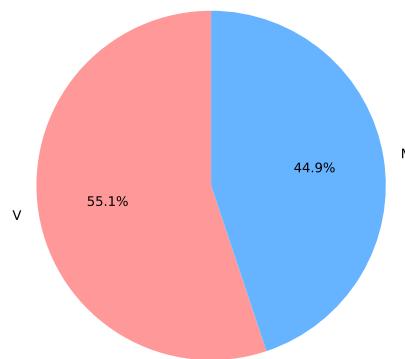


Figura 3.1: Distribución del género de los participantes

Distribución por edad:



- Rango de edad: 19 - 74 años
- Media: 38.5 años
- Mediana: 39.5 años
- Distribución: Predominantemente adultos jóvenes y de mediana edad

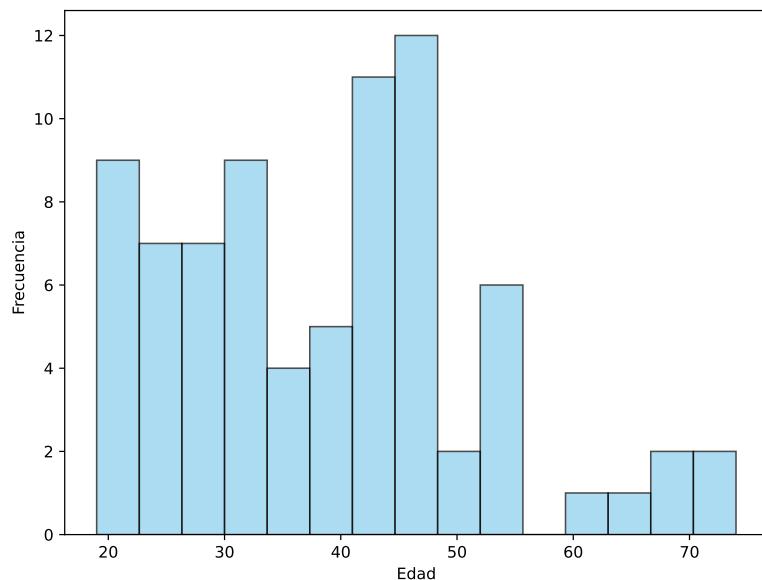


Figura 3.2: Histograma de las edades de los participantes

Características visuales:

- Uso de gafas: 18 participantes (23.4 %)
- Uso de lentillas: 9 participantes (11.7 %)
- Patologías: 4 participantes (5.2 %)



Estructura de los datos clínicos

Cada participante fue caracterizado mediante las siguientes variables, detalladas en la Tabla 3.1:

Tabla 3.1: Descripción de las variables clínicas recogidas por participante

Variable	Tipo	Descripción
NOMBRES	Categórica	Identificador único del participante (e.g., caso001)
FECHA ADQUISICIÓN	Temporal	Fecha en que se realizó la sesión de seguimiento ocular
SEXO	Categórica binaria	M (mujer) / V (varón)
EDAD	Numérica discreta	Edad del participante en años
GAFAS	Binaria	1 si usa gafas / 0 si no
LENTILLAS	Binaria	1 si usa lentillas / 0 si no
PATOLOGÍA	Binaria	1 si presenta alguna patología ocular / 0 si no

3.2.2 Estructura de los datos de seguimiento ocular

Los datos de comportamiento oculomotor fueron obtenidos mediante un sistema de eye tracking que registra la posición de la mirada a lo largo del tiempo. Cada punto de muestra incluye las siguientes variables:

- **pos_x:** Coordenada horizontal de la posición ocular, normalizada en el rango $[0, 1]$, donde 0 representa el borde izquierdo y 1 el borde derecho de la pantalla.
- **pos_y:** Coordenada vertical de la posición ocular, también normalizada en el rango $[0, 1]$, donde 0 corresponde a la parte superior y 1 a la inferior de la pantalla.
- **time_t:** Sello temporal (*timestamp*) en $10^{-5}s$, que indica el momento exacto en que fue registrada la muestra.

Todos estos datos tienen una resolución temporal con una frecuencia de muestreo de $1111 \cdot 10^{-5}s$, o $11,11ms$, lo que permite un análisis detallado de la dinámica visual.

Calidad de los datos

- **Consistencia:** La estructura general de los datos es coherente, cada muestra incluye las coordenadas normalizadas de la mirada y una marca temporal en milisegundos. Sin embargo, se detectan variaciones no uniformes en la tasa de muestreo (con diferencias de más de 100 ms entre muestras consecutivas), lo cual indica una tasa de adquisición variable o intermitente. Además, algunos valores presentan una resolución decimal



excesiva (hasta 10 dígitos), lo que podría deberse al formato de exportación del sistema y no refleja necesariamente una mayor precisión efectiva.

- **Ruido y artefactos:** Aunque la mayoría de las trayectorias muestran continuidad espacial suave, se observan saltos abruptos ocasionales que podrían deberse a movimientos sacádicos reales, pérdida temporal del seguimiento o artefactos del sistema, además de parpadeos ocasionales. Estos deberán ser cuidadosamente considerados o filtrados en el preprocesamiento antes de aplicar análisis cuantitativos.

Este conjunto de datos proporciona una base sólida para el análisis de patrones oculomotores y la generación de parámetros descriptores de la conducta visual en una población diversa de adultos con distintas características visuales.

3.3 Descripción de los experimentos

El protocolo experimental utilizado en este estudio comprende una batería de ocho tareas diseñadas para evaluar distintos aspectos de la conducta oculomotora de los participantes. Este conjunto de experimentos fue presentado de forma continua en formato audiovisual, con instrucciones visuales integradas, y una duración total de aproximadamente 16 minutos y medio.

Cada experimento está orientado al análisis de parámetros específicos como la *fijación*, la *ganancia de seguimiento*, la *latencia de sacadas*, la *precisión espacial* o el *control inhibitorio*, siguiendo las recomendaciones metodológicas establecidas por Duchowski en su obra *Eye Tracking Methodology: Theory and Practice* [11] y las directrices de Raynowska y Orquin [37]. A continuación, se describe cada uno de ellos en detalle.

3.3.1 Experimento 1: Fijación en puntos estáticos

Este primer experimento consistió en la presentación de un punto negro que aparecía secuencialmente en distintas posiciones de la pantalla (centro y ocho localizaciones periféricas). Se instruyó a los participantes para fijar la mirada en el punto, sin mover la cabeza, incluso cuando este permaneciera quieto durante varios segundos.

Este diseño permite analizar la capacidad de mantener la *fijación* y la estabilidad oculomotora, así como realizar tareas de calibración o validación del sistema de adquisición. Como señalan Rayner et al. [36], parámetros como la *desviación estándar* de la mirada durante las fijaciones son especialmente relevantes para evaluar la estabilidad del control oculomotor. Además, según Martínez-Conde et al. [28], la frecuencia de *microsacadas* constituye un indicador fundamental del control motor fino durante la fijación.



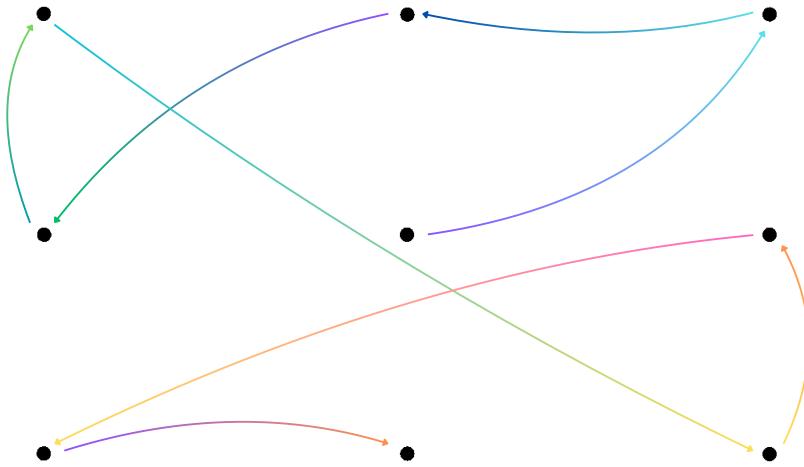


Figura 3.3: Visualización del primer experimento: fijación en puntos estáticos. En la imagen se observa la trayectoria de la mirada del participante durante la primera ronda.

3.3.2 Experimento 2: Seguimiento horizontal de un estímulo puntual

En esta tarea, el participante debía seguir un punto que se desplazaba de manera discreta en la dirección horizontal. El experimento incluyó tres rondas de 12 *trials* cada una, donde el estímulo se movía aleatoriamente a la izquierda o derecha del punto central.

Este paradigma, ampliamente documentado por Leigh y Zee en *The Neurology of Eye Movements* [25], permite obtener parámetros fundamentales como la *latencia* y *ganancia* de las *sacadas*, la *precisión espacial* del seguimiento y la capacidad atencional sostenida. Anderson y MacAskill [1] destacan la utilidad de estas *métricas* para detectar alteraciones motoras sutiles, mientras que Irving et al. [21] y Dowiasch et al. [10] han demostrado su sensibilidad a déficits relacionados con el envejecimiento.

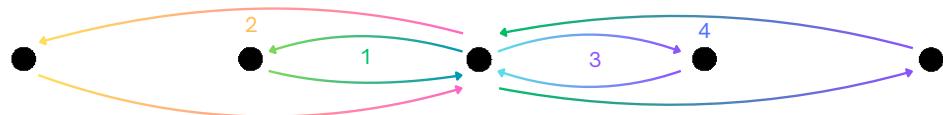


Figura 3.4: Visualización del segundo experimento: seguimiento horizontal de un estímulo puntual. En la imagen se observa la trayectoria de la mirada del participante durante la primera ronda.



3.3.3 Experimento 3: Tarea de antisacadas

Este experimento evalúa el *control inhibitorio* del sistema oculomotor siguiendo el paradigma clásico descrito por Munoz y Everling en su trabajo *Look away: The anti-saccade task and the voluntary control of eye movement* [31]. En cada *trial*, el participante debía mirar inicialmente al centro; cuando aparecía una flecha en un lado de la pantalla, debía redirigir su mirada hacia el lado opuesto, anticipando que el estímulo aparecería en esa ubicación.

Se realizaron tres rondas con 10 *trials* cada una, precedidas por un ejemplo explicativo. Crawford et al. [9] han demostrado la relevancia de esta tarea en el estudio del deterioro cognitivo asociado al Alzheimer, mientras que Benson et al. [5] han evidenciado su utilidad diagnóstica en esquizofrenia.

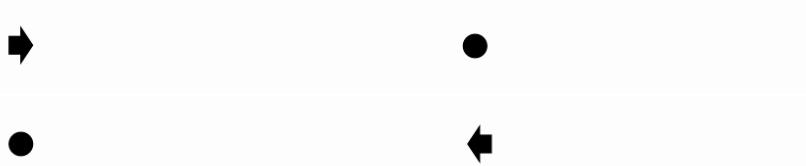


Figura 3.5: Visualización del tercer experimento: tarea de antisacadas. En las imágenes se muestran las dos alternativas: primero aparece la flecha a la que los participantes no deben mirar; deben mirar al lado contrario para esperar a que aparezca el punto.

Los parámetros derivados incluyen la tasa de errores de *antisacadas*, la *latencia* de ejecución y la *precisión espacial* del desplazamiento visual. Como establecen Hutton [20] y Falck-Ytter et al. [14], la capacidad de inhibir una respuesta refleja y ejecutar una alternativa voluntaria constituye un *biomarcador cognitivo* robusto de las funciones ejecutivas.

3.3.4 Experimento 4: Repetición del seguimiento horizontal

El cuarto experimento consistió en una repetición del protocolo del Experimento 2, es decir, una tarea de seguimiento de un estímulo puntual con desplazamientos horizontales. Se realizaron tres rondas adicionales con 10 *trials* cada una. Esta repetición permite evaluar la consistencia intraindividual del rendimiento oculomotor y la posible aparición de fatiga o aprendizaje a lo largo del experimento.

Siguiendo los planteamientos de Antoniades et al. [2] sobre herramientas de evaluación clínica, este diseño es útil para contrastar *métricas* como la *latencia* promedio de *sacadas* o el número de errores entre bloques sucesivos. Bargary et al. [3] han destacado la importancia de estos análisis para caracterizar las diferencias individuales en los patrones oculomotores y la estabilidad de la respuesta motora a estímulos repetidos.



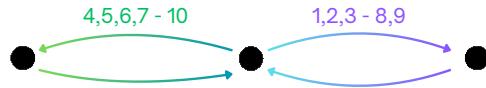


Figura 3.6: Visualización del cuarto experimento: seguimiento horizontal de un estímulo puntual. En la imagen se observa la trayectoria de la mirada del participante durante la primera ronda.

3.3.5 Experimento 5: Seguimiento de doble salto

Este experimento presentó una tarea más exigente desde el punto de vista temporal y espacial. El estímulo visual saltaba rápidamente a dos ubicaciones consecutivas y el participante debía seguir con la mirada ambas posiciones, manteniéndose en la segunda una vez estabilizado.

Cada una de las tres rondas incluyó 12 *trials*. Como indican Eckstein et al. [12], esta prueba es especialmente útil para estudiar la planificación de movimientos oculares múltiples y la coordinación entre *percepción* y *acción*. Molitor et al. [30] han demostrado la sensibilidad de este paradigma para detectar alteraciones tempranas en pacientes con *Alzheimer*, mientras que Peitsch et al. [35] han documentado su utilidad para evaluar la adaptación a trayectorias imprevistas. Las *métricas* extraíbles incluyen el *error espacial* de cada *sacada*, la *ganancia sacádica acumulada* y la *precisión* del reposicionamiento ocular.

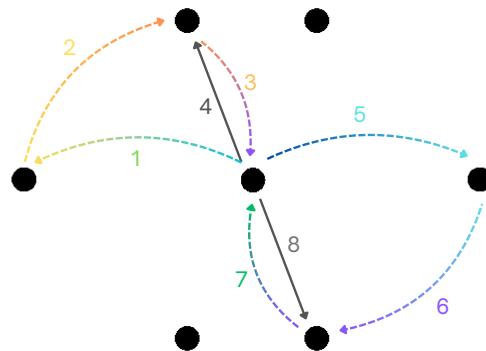


Figura 3.7: Visualización del quinto experimento: seguimiento de doble salto. En la imagen se observa la trayectoria que debería hacer el participante en color gris, y las líneas discontinuas proyectan el movimiento que realizan los puntos a una velocidad mucho más alta durante la primera ronda. Los números indican el orden en el que suceden los eventos.



3.3.6 Experimento 6: Seguimiento de trayectoria continua (*Lissajous*)

En este experimento se pidió al participante que siguiera un punto que se desplazaba suavemente siguiendo una curva de *Lissajous*. Se registraron tres rondas: una lenta, una con velocidad media y una en la que la velocidad aumentaba progresivamente.

Este paradigma, fundamentado en los trabajos de Barnes [4] sobre procesos cognitivos en el seguimiento ocular, evalúa el sistema de seguimiento continuo o *seguimiento suave*. Las *métricas* principales incluyen la *ganancia del seguimiento*, la suavidad del movimiento ocular (*smoothness*) y el retardo en el acoplamiento *estímulo-respuesta*. Según Leigh y Zee [25] y los hallazgos de Kasprowski y Harezlak [23], estas variables son particularmente sensibles a deterioros neurológicos tempranos.

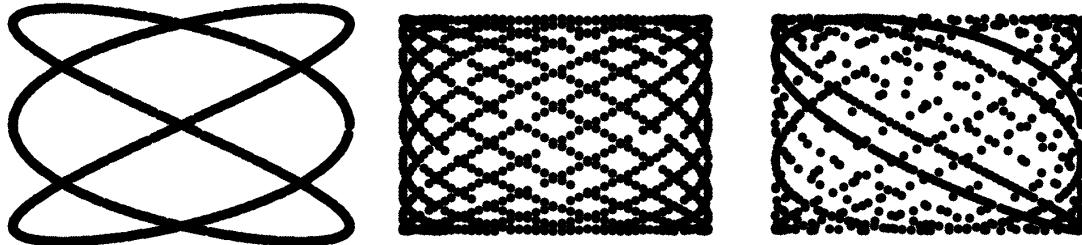


Figura 3.8: Visualización del sexto experimento: seguimiento de trayectoria continua (*Lissajous*). En la imagen se observa la trayectoria de la mirada del participante durante las tres rondas. Cada ronda presenta una velocidad diferente del movimiento del punto, aumentando progresivamente. De más lenta a más rápida de izquierda a derecha.

3.3.7 Experimento 7: Exploración libre de imágenes

En esta tarea se presentaron nueve imágenes consecutivas, cada una separada por un punto de centralización breve. Se pidió al participante que simplemente observara las imágenes “como quisiera”, sin instrucciones específicas sobre qué aspectos examinar o durante cuánto tiempo.

Esta modalidad de *exploración libre*, validada por Rayner et al. [36] y Tseng et al. [43], permite analizar patrones naturales de visualización sin sesgos instrucionales. El paradigma genera *mapas de calor*, trayectorias de exploración y *métricas* como número de *fijaciones*, duración media y amplitud de *sacadas*. Como han demostrado Borji [6] en sus estudios sobre predicción de *saliencia*, estos indicadores pueden revelar diferencias individuales significativas y establecer correlaciones con funciones cognitivas superiores.



Tabla 3.2: Cada imagen se mostró durante aproximadamente 7 segundos, intercaladas por puntos de transición centrales de 1 segundo para recentrar la mirada entre estímulos.

Imagen	Descripción
1	Imagen con apariencia solar, caracterizada por una paleta de colores rojizos que evocan una fuente de luz intensa y difusa.
2	Patrón de ruido visual estructurado verticalmente, compuesto por tonalidades turquesas y verdes que sugieren textura y profundidad cromática.
3	Representación naturalista de un entorno fluvial, con rápidos que atraviesan un bosque de árboles perennes con variaciones cromáticas estacionales.
4	Composición fractal simétrica con estructura geométrica repetitiva, evocando patrones complejos autorreferenciales.
5	Imagen de una playa tropical, con presencia de palmeras y un entorno paradisíaco que sugiere tranquilidad y calidez.
6	Escena de montaña nevada, caracterizada por una superficie blanca ininterrumpida en la que se observan discretas huellas, en un entorno minimalista.
7	Lago de aguas completamente quietas, con un reflejo especular nítido de árboles en la superficie, generando un efecto visual de simetría vertical.
8	Nueva imagen fractal, de mayor densidad visual y complejidad estructural que la anterior, con detalles minuciosos distribuidos simétricamente.
9	Patrón de ruido visual horizontal en la misma paleta turquesa que la imagen 2, generando continuidad perceptiva con una orientación distinta.

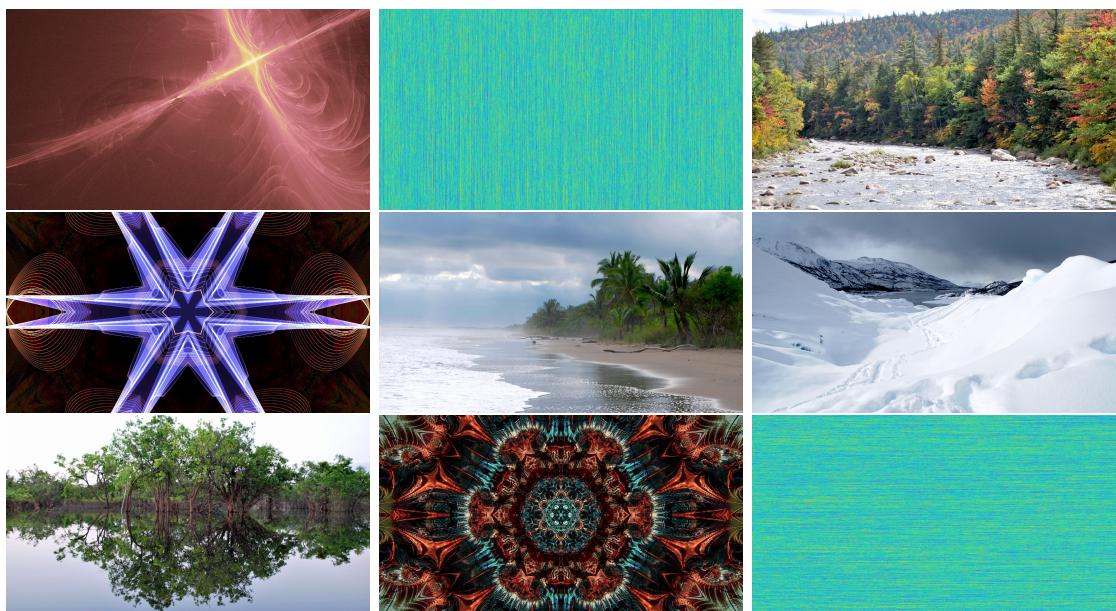


Figura 3.9: Visualización del séptimo experimento: exploración libre de imágenes.



3.3.8 Experimento 8: Tarea final de seguimiento horizontal

El último experimento fue una nueva variante del seguimiento horizontal del estímulo puntual, similar a los Experimentos 2 y 4. Se incluyeron dos rondas de 10 trials cada una. La repetición al final del protocolo permite analizar el posible efecto de la fatiga o del entrenamiento prolongado sobre las métricas de seguimiento, así como comparar el rendimiento respecto a las rondas anteriores. Dado que el diseño fue prácticamente idéntico al del Experimento 4, se ha reutilizado la Figura 3.6 para ilustrar esta tarea.

Siguiendo los planteamientos de Dowiasch et al. [10] sobre efectos del envejecimiento en movimientos oculares y los hallazgos de Cole y Franke [8] sobre biomarcadores neurológicos, este diseño contribuye a observar fenómenos como la habituación, la variabilidad intraindividual o la estabilidad del control oculomotor bajo condiciones de repetición prolongada.

3.4 Preprocesado y calibración temporal de los datos

En esta sección se describe el flujo de trabajo completo de preprocesado y calibración temporal aplicado a los datos crudos del sistema de seguimiento ocular. El proceso se divide en varias etapas consecutivas que incluyen la conversión de formatos, el filtrado de artefactos, el remuestreo de la señal, la calibración espacial y temporal, y la segmentación por experimentos.

3.4.1 Arquitectura del sistema de procesamiento

El sistema de procesamiento se estructura mediante una función principal denominada `preprocesado()`, que coordina la ejecución secuencial de las diferentes etapas del pipeline. Esta función recibe como parámetros el identificador numérico del caso a procesar y un indicador booleano para la eliminación opcional de archivos previamente procesados.

La arquitectura modular permite la reutilización de componentes individuales y facilita la trazabilidad del proceso, generando archivos intermedios en diferentes etapas que pueden ser utilizados para verificación y depuración.



3.4.2 Conversión y validación de formatos

3.4.2.1 Conversión JSON a formato MAT

Los datos crudos del eye tracker se almacenan inicialmente en formato JSON, que debe ser convertido a formato MAT de MATLAB para su procesamiento posterior. La función `leer_json_videos_new()` realiza esta conversión mediante un análisis línea por línea del archivo JSON, extrayendo las variables principales:

- `posicion_x`: Coordenadas horizontales de la mirada
- `posicion_y`: Coordenadas verticales de la mirada
- `time_t`: Sellos temporales en milisegundos
- `frame`: Número de frame correspondiente

El proceso de conversión incluye validación automática de la existencia de archivos y manejo de errores para casos donde los archivos de entrada no están disponibles.

3.4.2.2 Estructura de archivos

La organización de archivos sigue una estructura jerárquica que separa los datos por etapas de procesamiento:

- `datos/jsons/`: Archivos originales en formato JSON
- `datos/mats/`: Archivos convertidos a formato MAT
- `datos/preprocesado/`: Archivos procesados y remuestreados
- `datos/calibrado/`: Archivos con calibración temporal aplicada
- `datos/expto_divididos/`: Datos segmentados por experimento

3.4.3 Filtrado de artefactos y preprocesamiento

3.4.3.1 Eliminación de parpadeos

El primer paso del preprocesamiento consiste en la eliminación de artefactos producidos por los parpadeos del participante. Esta tarea se realiza mediante la función `filtrar_parpadeos()`, que identifica y elimina las muestras correspondientes a períodos de oclusión ocular.



Los algoritmos de detección de parpadeos utilizan criterios basados en la continuidad temporal y espacial de las trayectorias oculares, permitiendo la identificación automática de interrupciones en la señal causadas por el cierre de los párpados.

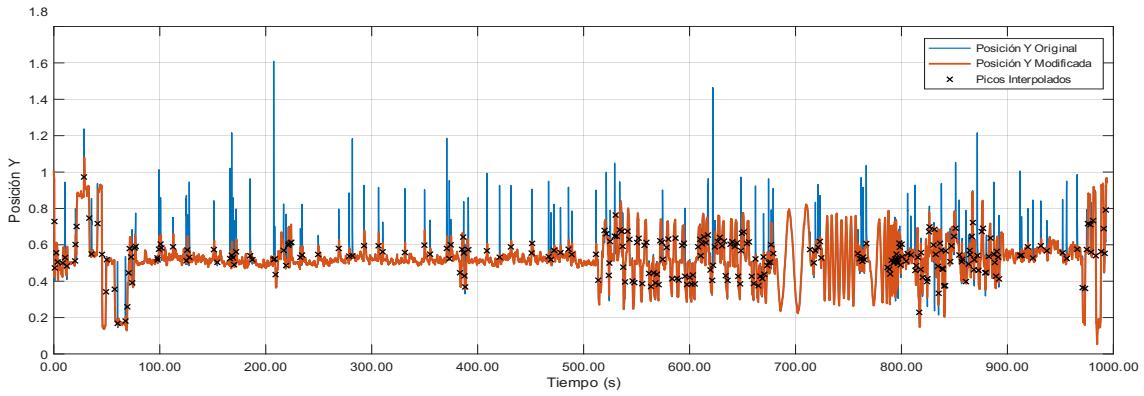


Figura 3.10: Visualización de la eliminación de los parpadeos.

Los parámetros optimizados para la detección incluyen un umbral de diferencia de 0.020 unidades y un tamaño de ventana de 20 muestras. Estos valores fueron determinados mediante análisis iterativo de la señal, considerando las características específicas del ruido y la variabilidad natural de los movimientos oculares registrados.

El análisis cuantitativo de los datos procesados, para el caso 34 mostrado en la 3.10, reveló la detección de 272 eventos de parpadeo durante un período de registro de 16.57 minutos como se puede ver en la figura 3.10, esta información permitió calcular una frecuencia media de parpadeo de 16.42 eventos por minuto, valor que se encuentra dentro del rango fisiológico normal establecido entre 15 y 20 parpadeos por minuto para individuos en condiciones de reposo.

3.4.3.2 Remuestreo de la señal

La función `remuestreo_señal()` realiza la normalización temporal de los datos mediante las siguientes operaciones:

1. **Recorte temporal:** Eliminación de muestras posteriores a 985.00290 segundos para estandarizar la duración de las sesiones.
2. **Remuestreo uniforme:** Aplicación de interpolación lineal para generar una señal con muestreo regular de 1110 microsegundos.
3. **Centrado de la señal:** Sustracción del valor medio de cada coordenada para eliminar el offset DC.



El proceso de remuestreo asegura la coherencia temporal entre diferentes sesiones y facilita la aplicación de algoritmos de procesamiento posteriores que requieren muestreo uniforme.

3.4.4 Sistema de calibración temporal adaptativo

3.4.4.1 Detección de fijaciones mediante clustering espacial

El sistema de calibración temporal se basa en la identificación automática de períodos de fijación ocular mediante técnicas de clustering espacial. La función `visualizar_fijaciones_espaciales()` implementa un algoritmo de clustering por densidad que agrupa las muestras oculares según criterios de proximidad espacial y temporal.

Los parámetros del algoritmo de clustering son:

- `max_dist`: Distancia máxima entre puntos para formar un cluster (0.004 unidades normalizadas).
- `max_time_gap`: Intervalo temporal máximo entre muestras del mismo cluster (0.015 segundos).
- `min_points`: Número mínimo de puntos requeridos para formar un cluster válido (45 muestras).

3.4.4.2 Formación de super-clusters

Para mejorar la robustez de la detección de fijaciones, se implementa un sistema de agrupación jerárquico que combina clusters espacialmente próximos en estructuras denominadas super-clusters. La función `detectar_super_clusters()` utiliza un criterio de distancia entre centros de clusters para determinar la pertenencia a un super-cluster.

Esta aproximación jerárquica permite la identificación de fijaciones complejas que pueden manifestarse como múltiples clusters espaciales debido a micro-movimientos oculares o variaciones en la precisión del sistema de seguimiento. Estos clusters se pueden visualizar en la figura 3.14.

3.4.4.3 Calibración temporal basada en sacadas

El proceso de calibración temporal se fundamenta en la sincronización de los tiempos de las sacadas detectadas con un patrón temporal de referencia predefinido. La función `calibrar_con_fijaciones()` realiza las siguientes operaciones:



1. **Extracción de tiempos de sacada:** Identificación de los instantes temporales correspondientes a las transiciones entre fijaciones.
2. **Alineación temporal:** Cálculo del desplazamiento temporal óptimo mediante minimización del error cuadrático medio entre sacadas detectadas y tiempos objetivo.
3. **Aplicación de corrección:** Ajuste de todos los sellos temporales mediante la adición del desplazamiento calculado.

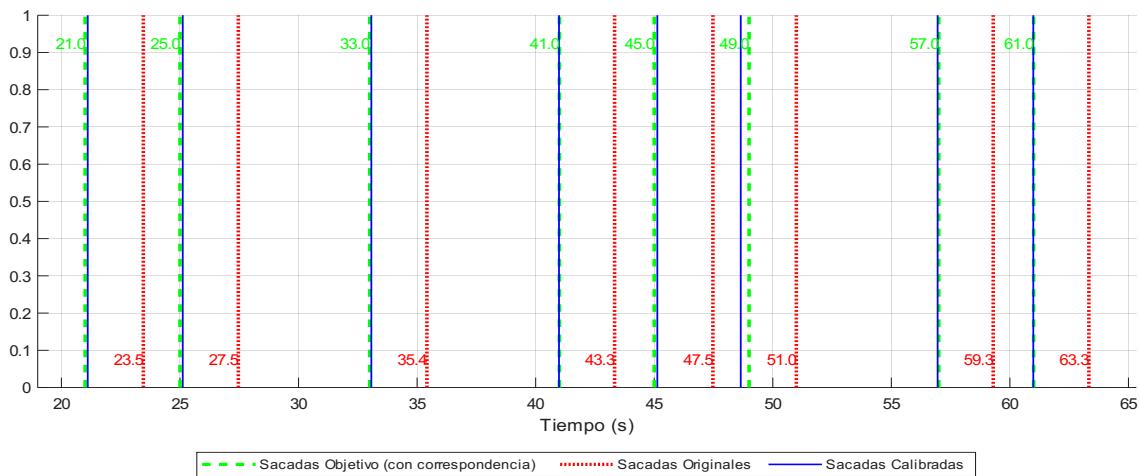


Figura 3.11: Visualización de la calibración temporal. En este caso se retrasan todas las muestras de este caso unos 2.5 segundos para que coincidan con los tiempos objetivo de las sacadas.

Los tiempos objetivo de las sacadas están predefinidos en segundos: [21, 25, 33, 41, 45, 49, 57, 61], correspondientes a las transiciones esperadas en el protocolo experimental utilizado.

3.4.5 Calibración espacial

3.4.5.1 Calibración en el eje X (horizontal)

La calibración espacial en el eje horizontal se realiza mediante un proceso de tres etapas que utiliza intervalos temporales específicos correspondientes a diferentes zonas de calibración:

- **Calibración central:** Intervalos [26-32] y [62-68] segundos para establecer el punto de referencia central.
- **Calibración izquierda:** Intervalo [34-44] segundos para la zona izquierda de la pantalla.
- **Calibración derecha:** Intervalo [46-56] segundos para la zona derecha de la pantalla.



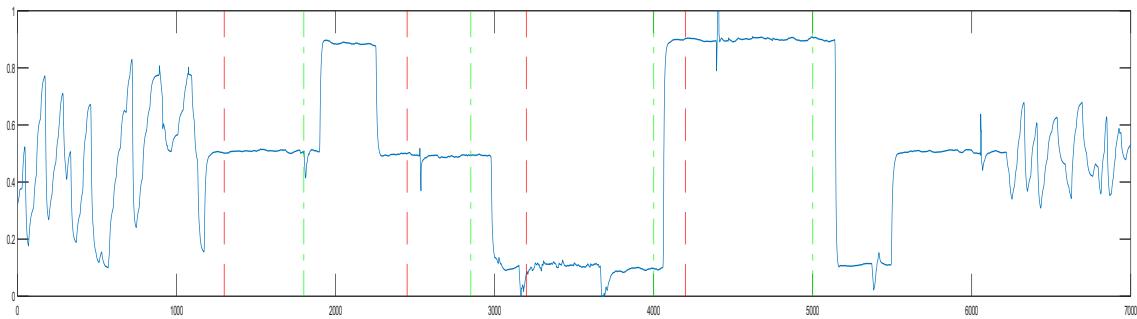


Figura 3.12: Zona de calibración de la señal del eje X.

El proceso incluye la aplicación de factores de escalado diferenciados para las zonas izquierda y derecha (factor 0.4), seguido de limitación de valores extremos al rango [-0.5, 0.5] y traslación final al rango [0, 1].

3.4.5.2 Calibración en el eje Y (vertical)

La calibración vertical sigue un esquema similar al horizontal, utilizando los siguientes intervalos temporales:

- **Calibración central:** Intervalos [34-40] y [50-56] segundos.
- **Calibración inferior:** Intervalo [22-32] segundos.
- **Calibración superior:** Intervalo [58-68] segundos.

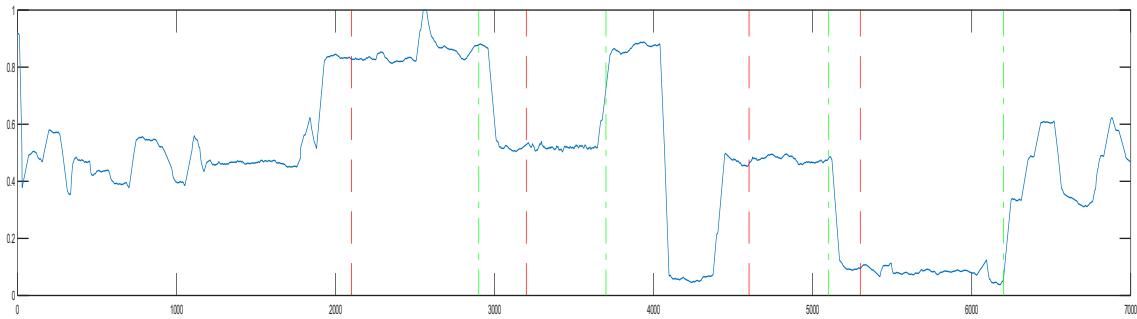


Figura 3.13: Calibración de la señal del eje Y.

Los factores de escalado y las operaciones de limitación y traslación siguen el mismo procedimiento que en el eje horizontal.



3.4.6 Procesamiento final y segmentación

3.4.6.1 Eliminación de transitorios

Para minimizar los efectos de transitorios al inicio y final de cada sesión, se aplica una ventana de eliminación que establece a cero las primeras y últimas 200 muestras de cada señal procesada.

3.4.6.2 Segmentación por experimentos

La función `extraer_experimentos()` realiza la segmentación temporal de los datos procesados según la estructura del protocolo experimental. Los intervalos de segmentación están predefinidos para ocho experimentos diferentes, cada uno con múltiples rondas:

- Experimento 1: Una ronda de calibración entre 13.0 y 69.0 segundos
- Experimento 2: Tres rondas entre 80.0 y 208.767 segundos
- Experimento 3: Tres rondas entre 227.933 y 382.833 segundos
- Experimento 4: Tres rondas entre 393.8 y 513.3 segundos
- Experimento 5: Tres rondas entre 527.3 y 672.1 segundos
- Experimento 6: Tres rondas entre 680.0 y 803.0 segundos
- Experimento 7: Nueve rondas entre 812.0 y 887.0 segundos
- Experimento 8: Tres rondas entre 898.633 y 990.5 segundos

Cada segmento se almacena como un archivo independiente que contiene las coordenadas oculares y los sellos temporales correspondientes al experimento y ronda específicos.

```

proyecto/
|-- datos/
  |-- expto_divididos/
    |-- expto_divididos_caso042/
      |-- experimento_1_ronda_1.mat
      |-- experimento_2_ronda_1.mat
      |-- experimento_2_ronda_2.mat
      |-- experimento_2_ronda_3.mat
      |-- experimento_3_ronda_1.mat
      |-- experimento_3_ronda_2.mat
      |-- experimento_3_ronda_3.mat

```



```

...
|-- experimento_8_ronda_1.mat
|-- experimento_8_ronda_2.mat
`-- experimento_8_ronda_3.mat
4 directories, 28 files

```

3.4.7 Validación y control de calidad

El sistema incluye múltiples mecanismos de validación y control de calidad:

- **Verificación de longitud:** Confirmación de la coherencia dimensional entre vectores de coordenadas y tiempo.
- **Validación temporal:** Comprobación de la alineación correcta de las sacadas calibradas con los tiempos objetivo.
- **Reporte de estadísticas:** Generación automática de informes con métricas de calibración y desplazamientos aplicados.
- **Trazabilidad completa:** Mantenimiento de registros detallados de todas las transformaciones aplicadas.

3.4.8 Consideraciones técnicas

3.4.8.1 Robustez del algoritmo

El sistema de procesamiento incorpora mecanismos de robustez para manejar variaciones en la calidad de los datos y diferencias interindividuales:

- Adaptación automática al número de clusters detectados
- Selección óptima de correspondencias entre sacadas detectadas y objetivos
- Manejo de casos con información parcial o degradada

3.4.8.2 Escalabilidad

La arquitectura modular del sistema permite el procesamiento eficiente de grandes volúmenes de datos, con parallelización potencial en las etapas de conversión y filtrado de artefactos.

El pipeline completo de preprocessado y calibración proporciona datos normalizados tanto espacial como temporalmente, facilitando los análisis posteriores de patrones oculomotores y la extracción de parámetros descriptores de la conducta visual.



3.5 Detección de fijaciones y sacadas

La detección precisa de fijaciones y sacadas constituye un paso fundamental en el análisis de movimientos oculares, ya que estos eventos representan las unidades básicas de comportamiento oculomotor [11]. Las fijaciones corresponden a períodos de relativa estabilidad ocular durante los cuales se procesa la información visual, mientras que las sacadas representan movimientos balísticos rápidos entre puntos de fijación [36].

3.5.1 Fundamentos teóricos

La identificación de eventos oculomotores se basa en el análisis de las características temporales y espaciales de los movimientos oculares registrados. Según [37], los algoritmos de detección pueden clasificarse en tres categorías principales: basados en velocidad, basados en dispersión y basados en modelos probabilísticos. Para el presente trabajo se adoptó un enfoque híbrido que combina criterios de velocidad y dispersión espacial, siguiendo las recomendaciones metodológicas establecidas en la literatura especializada [1, 12].

El algoritmo implementado se fundamenta en el principio de que las fijaciones se caracterizan por velocidades angulares bajas y agrupación espacial de puntos consecutivos, mientras que las sacadas presentan velocidades elevadas y desplazamientos espaciales significativos [41]. Esta aproximación permite una identificación robusta de eventos oculomotores incluso en presencia de ruido en las señales [30].

3.5.2 Algoritmo de detección

3.5.2.1 Cálculo de velocidades

El primer paso del algoritmo consiste en el cálculo de velocidades instantáneas entre puntos consecutivos de la trayectoria ocular. Para cada par de muestras consecutivas (x_i, y_i, t_i) y $(x_{i+1}, y_{i+1}, t_{i+1})$, la velocidad se calcula mediante:

$$v_i = \frac{\sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}}{t_{i+1} - t_i} \quad (3.1)$$

donde v_i representa la velocidad instantánea en el punto i , expresada en unidades de posición por unidad de tiempo. La conversión temporal se realiza multiplicando por un factor de escala de 10^{-5} para convertir las unidades temporales del sistema de adquisición a segundos.



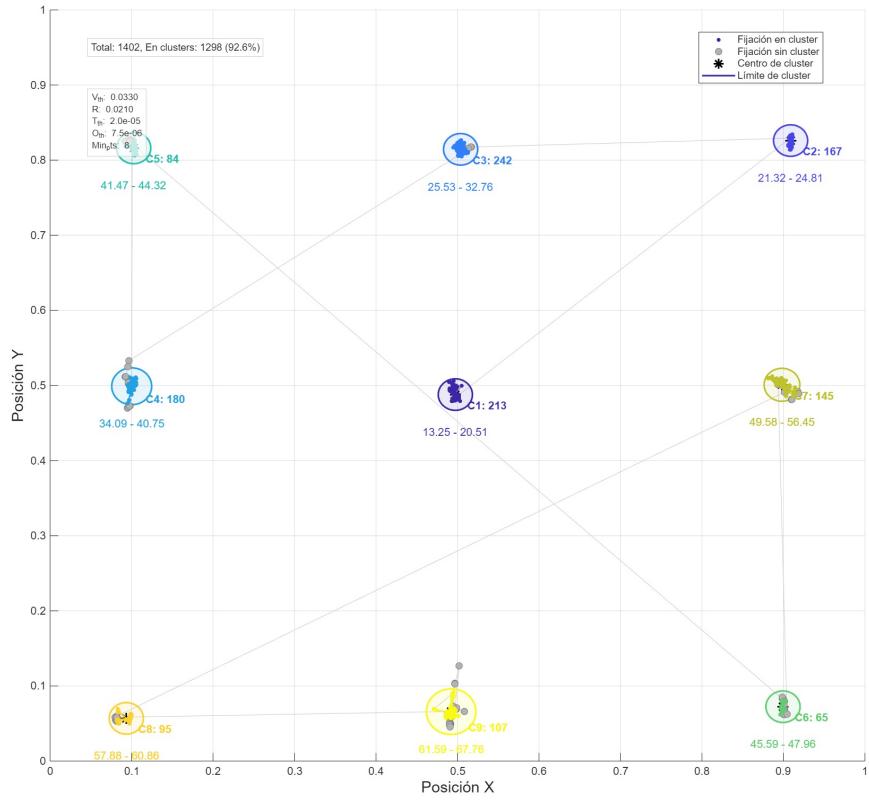


Figura 3.14: Gráfica de los *cluster* agrupados de cada fijación. El ejemplo muestra el experimento que se usa para calibrar temporalmente todos los casos, ademas de para calibrar el propio *eye tracker*.

3.5.2.2 Clasificación basada en umbral de velocidad

La identificación inicial de fijaciones se realiza mediante la aplicación de un umbral de velocidad $V_{threshold}$. Los puntos que satisfacen la condición $v_i < V_{threshold}$ se clasifican como candidatos a fijación [27]. El valor del umbral se establece inicialmente en 0.0275 unidades por segundo, basándose en los parámetros reportados en estudios previos sobre análisis oculomotor [9, 31].



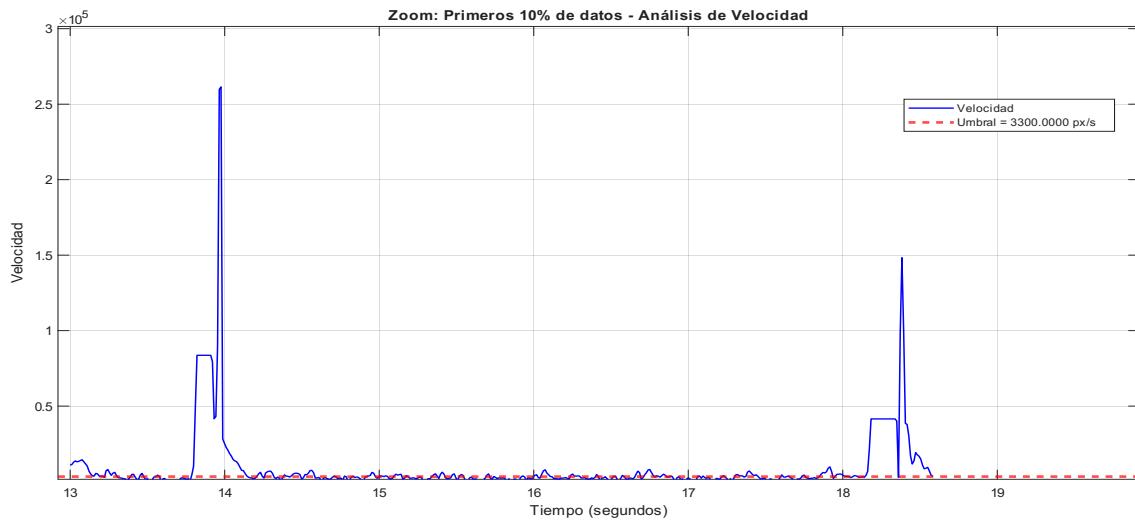


Figura 3.15: Visulización de la velocidad entre muestras con el umbral de velocidad.

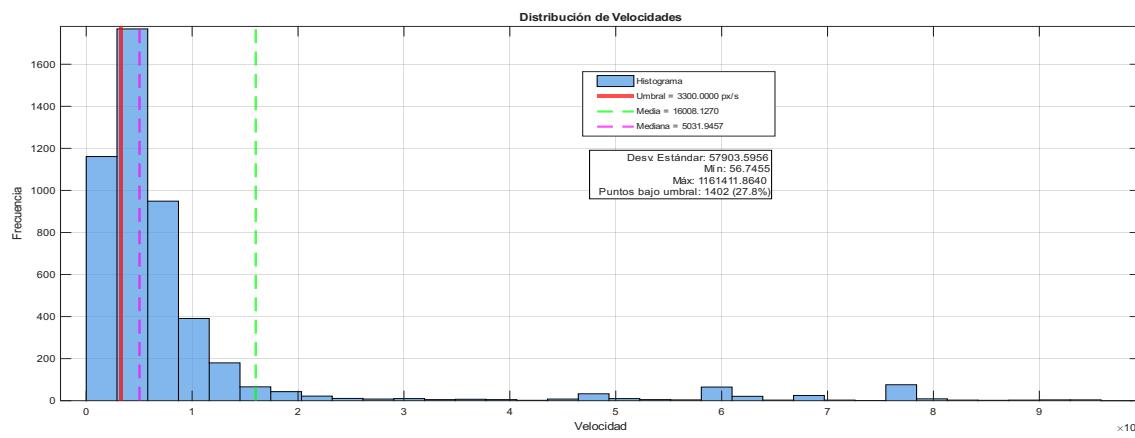


Figura 3.16: Visulización del histograma la velocidad.



3.5.2.3 Agrupación espacial y temporal

Los puntos candidatos a fijación se someten a un proceso de agrupación que considera tanto la proximidad espacial como la continuidad temporal. Se implementa un algoritmo de clustering que evalúa:

- **Distancia espacial:** Los puntos se agrupan si la distancia euclídea entre sus centroides es inferior a un umbral espacial de 0.004 unidades
- **Continuidad temporal:** Se requiere que el intervalo temporal entre grupos consecutivos sea inferior a 0.015 segundos para considerar su fusión
- **Número mínimo de puntos:** Cada cluster debe contener al menos 3 puntos para ser considerado una fijación válida

Esta aproximación multicriterio permite identificar fijaciones coherentes desde el punto de vista oculomotor, siguiendo los principios establecidos por [14] para la detección de patrones oculares en poblaciones clínicas.

3.5.3 Refinamiento y optimización de parámetros

3.5.3.1 Combinación de clusters espacialmente próximos

El algoritmo implementa un proceso iterativo de refinamiento que evalúa la posibilidad de combinar clusters espacialmente próximos. Para cada par de clusters C_i y C_j , se calcula:

- **Distancia entre centroides:** $d_{ij} = \sqrt{(x_{C_i} - x_{C_j})^2 + (y_{C_i} - y_{C_j})^2}$
- **Área de solapamiento:** Calculada geométricamente considerando los radios respectivos r_i y r_j
- **Diferencia temporal:** Mínima separación temporal entre los intervalos de ambos clusters

Los clusters se combinan si el porcentaje de solapamiento supera el 75 % del área del cluster menor y la diferencia temporal es inferior a 2×10^{-5} segundos. Esta estrategia permite la identificación de fijaciones complejas que pueden presentar micro-movimientos internos [28].

3.5.3.2 Optimización automática de parámetros

Se implementó un sistema de optimización automática que ajusta los parámetros del algoritmo basándose en métricas de calidad de los clusters resultantes. La función objetivo considera:



$$Score = 0,4 \cdot S_{cohesion} + 0,2 \cdot S_{separation} + 0,3 \cdot S_{coverage} + 0,1 \cdot S_{clusters} \quad (3.2)$$

Donde:

- $S_{cohesion}$: Inversamente proporcional a la distancia promedio intra-cluster.
- $S_{separation}$: Proporcional a la distancia promedio inter-cluster.
- $S_{coverage}$: Proporción de puntos asignados a clusters válidos.
- $S_{clusters}$: Penalización por número excesivo o insuficiente de clusters.

Los parámetros optimizados incluyen:

- **Umbral de velocidad $V_{threshold}$** : Rango de exploración $\pm 20\%$ del valor inicial.
- **Radio de clusters $radius$** : Rango de exploración $\pm 20\%$ del valor inicial.
- **Umbral temporal $time_{threshold}$** : Rango de exploración $\pm 20\%$ del valor inicial.
- **Umbral de solapamiento $overlap_{threshold}$** : Rango de exploración $\pm 20\%$ del valor inicial.
- **Número mínimo de puntos por cluster $min_{fij_cluster}$** : Rango de exploración ± 2 del valor inicial.

Esta aproximación adaptativa permite ajustar automáticamente los parámetros de detección a las características específicas de cada registro, mejorando la robustez del análisis [2].

3.5.4 Validación y control de calidad

La validación de los resultados de detección se realiza mediante inspección visual utilizando una función de representación gráfica especializada que permite evaluar:

- Distribución espacial de fijaciones y clusters
- Coherencia temporal de las agrupaciones
- Proporción de puntos asignados correctamente
- Identificación de posibles artefactos o errores de clasificación

Esta aproximación visual complementa las métricas automáticas de calidad, proporcionando una validación cualitativa esencial para garantizar la fiabilidad de los resultados [43]. La representación gráfica incluye elementos distintivos para cada tipo de evento ocular, facilitando la interpretación por parte del investigador.



3.5.5 Parámetros de salida

El algoritmo genera una estructura de datos completa que incluye:

- **Puntos de fijación:** Coordenadas espaciales, marcas temporales y asignación a clusters
- **Características de clusters:** Centroides, radios, intervalos temporales y número de puntos
- **Parámetros optimizados:** Valores ajustados de todos los umbrales utilizados
- **Métricas de calidad:** Puntuaciones de cohesión, separación y cobertura

Esta información constituye la base para la extracción posterior de parámetros oculomotores específicos, siguiendo las metodologías establecidas en la literatura para el análisis de movimientos oculares en contextos clínicos y experimentales [4, 15].

La implementación desarrollada proporciona una base sólida para el análisis cuantitativo de patrones oculomotores, permitiendo la extracción de biomarcadores relacionados con el envejecimiento y el funcionamiento neurológico [10, 3].

3.6 Parámetros oculomotores extraídos

La extracción de parámetros oculomotores representa una etapa fundamental en el análisis cuantitativo de los movimientos oculares, ya que permite transformar las señales de seguimiento ocular en métricas objetivas que reflejan aspectos específicos del comportamiento visual y cognitivo. Los parámetros oculomotores constituyen biomarcadores potenciales que han demostrado su capacidad para caracterizar diferencias individuales, estados cognitivos y procesos de envejecimiento [3].

El procesamiento de las señales de eye tracking para la obtención de parámetros cuantitativos requiere de metodologías robustas que permitan extraer información relevante de los patrones de movimientos oculares. Según Duchowski (2017) en su obra fundamental “Eye Tracking Methodology: Theory and Practice” [11], la selección y cálculo de estos parámetros debe fundamentarse en la comprensión de los mecanismos neurofisiológicos subyacentes a cada tipo de movimiento ocular, así como en su relevancia para la aplicación específica del estudio.

En el contexto de la predicción de la edad biológica, diversos estudios han identificado que ciertos parámetros oculomotores experimentan cambios sistemáticos a lo largo del ciclo vital. Irving et al. (2006) en su investigación sobre la dinámica de sacadas horizontales a lo largo de la vida humana [21] y Peltsch et al. (2011) en su análisis de tendencias relacionadas



con la edad en las características de sacadas en adultos mayores [35] han documentado que parámetros como la latencia de sacadas, la precisión espacial y la ganancia sacádica muestran tendencias específicas relacionadas con el envejecimiento, lo que fundamenta su uso como predictores potenciales de la edad cronológica.

La metodología implementada para la extracción de parámetros se basa en el análisis de las secuencias de fijaciones y sacadas previamente detectadas, aplicando algoritmos específicos para cada tipo de parámetro. A continuación se describe el proceso de cálculo de cada parámetro oculomotor utilizado en este trabajo.

3.6.1 Ganancia de sacadas (*Saccadic Gain*)

Definición y relevancia clínica

La *ganancia de sacadas* se define como la relación entre la amplitud del movimiento ocular ejecutado y la amplitud del desplazamiento requerido para alcanzar el objetivo visual [25]. Este parámetro es una medida fundamental de la precisión del sistema oculomotor y ha sido identificado como biomarcador sensible a procesos neurológicos y de envejecimiento [1, 27].

Fundamentos teóricos

En individuos jóvenes y sanos, la *ganancia sacádica* suele aproximarse a la unidad, indicando que el movimiento ocular cubre la distancia necesaria para alcanzar el objetivo. Factores como la edad, condiciones neurológicas y la complejidad de la tarea pueden alterar este valor [27]. La literatura destaca la importancia de este parámetro en la evaluación de la función oculomotora y su utilidad clínica en el diagnóstico de trastornos neurodegenerativos [1].

Metodología de cálculo

El cálculo de la *ganancia de sacadas* sigue estos pasos, adaptados de Terao et al. (2017) [41]:

1. **Identificación de sacadas:** Para cada estímulo, se identifican las fijaciones dentro de una ventana temporal de 500 ms antes y después del estímulo, siguiendo a Molitor et al. (2015) [30].
2. **Selección de fijaciones relevantes:** Se requieren al menos dos fijaciones para calcular la ganancia. Se identifican la primera y última fijación asociadas al estímulo como posiciones inicial y final del movimiento ocular.
3. **Cálculo de amplitudes:**



- *Amplitud del estímulo:* Distancia entre la posición central de referencia (0.5 en coordenadas normalizadas) y la posición del estímulo.
- *Amplitud del movimiento ocular:* Distancia euclídea entre las fijaciones inicial y final.

4. Cálculo de la ganancia:

$$Ganancia = \frac{\text{Amplitud del movimiento ocular}}{\text{Amplitud del estímulo}} \quad (3.3)$$

donde el numerador es la distancia recorrida por la mirada y el denominador la distancia requerida por el estímulo.

5. Filtrado de valores:

Se excluyen valores fuera del intervalo [0.1, 2.0], según Eckstein et al. (2017) [12].

Si solo se identifica una fijación dentro del periodo del estímulo, se utiliza la fijación inmediatamente anterior como referencia, siguiendo a Fukushima y Fukushima (2013) [15].

Criterios de validación

La validez del cálculo se garantiza mediante:

- Aplicación de ventanas temporales amplias para capturar respuestas rápidas y tardías [9].
- Exclusión de valores fuera del rango [0.1, 2.0], que suelen corresponder a artefactos o movimientos no relacionados [31].
- Validación visual de las trayectorias y fijaciones.

Parámetros extraídos

A partir del análisis de la *ganancia de sacadas* se obtienen:

- **Ganancia media:** Valor promedio de todas las sacadas válidas por participante.
- **Distribución de ganancias:** Vector de valores individuales para análisis intra- e inter-sujeto.

Visualización

La visualización incluye la representación de las posiciones de fijaciones, trayectorias de sacadas y valores de ganancia calculados. Esta funcionalidad es esencial para la validación y análisis cualitativo de los resultados, siguiendo las recomendaciones de Antoniades et al. (2013) [2].



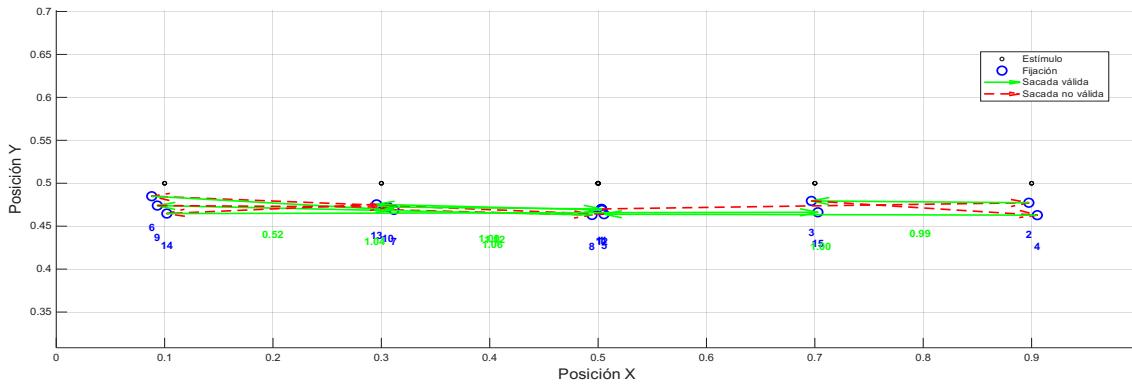


Figura 3.17: Ejemplo de visualización de las ganancias de las sacadas calculadas para un participante.

Consideraciones técnicas

La implementación computacional incorpora filtros de calidad, validación visual y criterios conservadores para asegurar la robustez de los resultados. La *ganancia de sacadas* debe interpretarse en el contexto experimental y en conjunto con otros parámetros oculomotores para una caracterización integral del desempeño visual.

En síntesis, la *ganancia de sacadas* es un parámetro esencial para la evaluación cuantitativa de la precisión oculomotora, aportando valor diagnóstico y comparativo en estudios de función

3.6.2 Sacadas correctivas (*Corrective Saccades*)

Definición y relevancia clínica

Las *sacadas correctivas* constituyen un tipo específico de movimiento ocular de pequeña amplitud, cuya función es compensar errores residuales tras una sacada primaria. Estas sacadas desempeñan un papel crucial en el mantenimiento de la precisión visual y reflejan la eficiencia del sistema de control oculomotor [28]. Su frecuencia y características han sido propuestas como biomarcadores sensibles a procesos de envejecimiento y disfunción neurológica [10].

Fundamentos teóricos

La literatura destaca que las *sacadas correctivas* reflejan mecanismos de retroalimentación visual y la capacidad del sistema oculomotor para corregir errores de fijación. Cambios en la frecuencia o en las características de estas sacadas pueden indicar alteraciones en el control motor fino, siendo relevantes en el contexto del envejecimiento y los trastornos neurodegenerativos [10, 41].



Metodología de cálculo

La detección y cuantificación de *sacadas correctivas* se basa en el análisis de desviaciones temporales de la mirada fuera de los límites de los *clusters* de fijación previamente identificados. El procedimiento sigue estos pasos:

1. **Definición del intervalo temporal:** Para cada *cluster* de fijación, se establece su intervalo temporal mediante los tiempos de inicio (t_{start}) y finalización (t_{end}).
2. **Identificación de puntos fuera del radio:** Se calcula la distancia euclíadiana de cada punto de mirada al centro del *cluster*. Los puntos que exceden el radio establecido se consideran candidatos a *sacada correctiva*.
3. **Agrupación de secuencias consecutivas:** Los puntos fuera del radio se agrupan en secuencias temporalmente consecutivas, siguiendo los criterios de Eckstein et al. (2017) [12].
4. **Cálculo de parámetros cuantitativos:** Para cada secuencia identificada se calculan:
 - *Distancia máxima:* Máxima distancia alcanzada fuera del límite del *cluster*.
 - *Duración:* Tiempo entre el primer y último punto de la secuencia.
 - *Coordenadas de trayectoria:* Registro completo de posiciones x , y y tiempos de cada punto de la *sacada correctiva*.

Criterios de validación

La validación sigue los estándares metodológicos de Molitor et al. (2015) [30]:

- Se requiere un mínimo de dos puntos consecutivos fuera del radio del *cluster* para considerar válida una *sacada correctiva*.
- Control de calidad temporal y espacial de las secuencias detectadas.
- Verificación de que los índices calculados estén dentro de los límites válidos de los datos registrados [3].

Parámetros extraídos

A partir de las *sacadas correctivas* detectadas se obtienen:

- **Frecuencia de *sacadas correctivas*:** Número total por *cluster* válido, normalizado por la duración total del experimento.
- **Distancia máxima promedio:** Media de las distancias máximas alcanzadas fuera de los límites de los *clusters*.
- **Duración promedio:** Media de las duraciones de todas las *sacadas correctivas*.



- **Proporción de *clusters* afectados:** Porcentaje de *clusters* de fijación con al menos una *sacada correctiva*.

Estas características se fundamentan en la evidencia de Terao et al. (2017) [41].

Visualización

La visualización incluye la representación de la trayectoria de cada *sacada correctiva* sobre los *clusters* correspondientes, permitiendo la inspección manual y validación visual de los resultados [9].

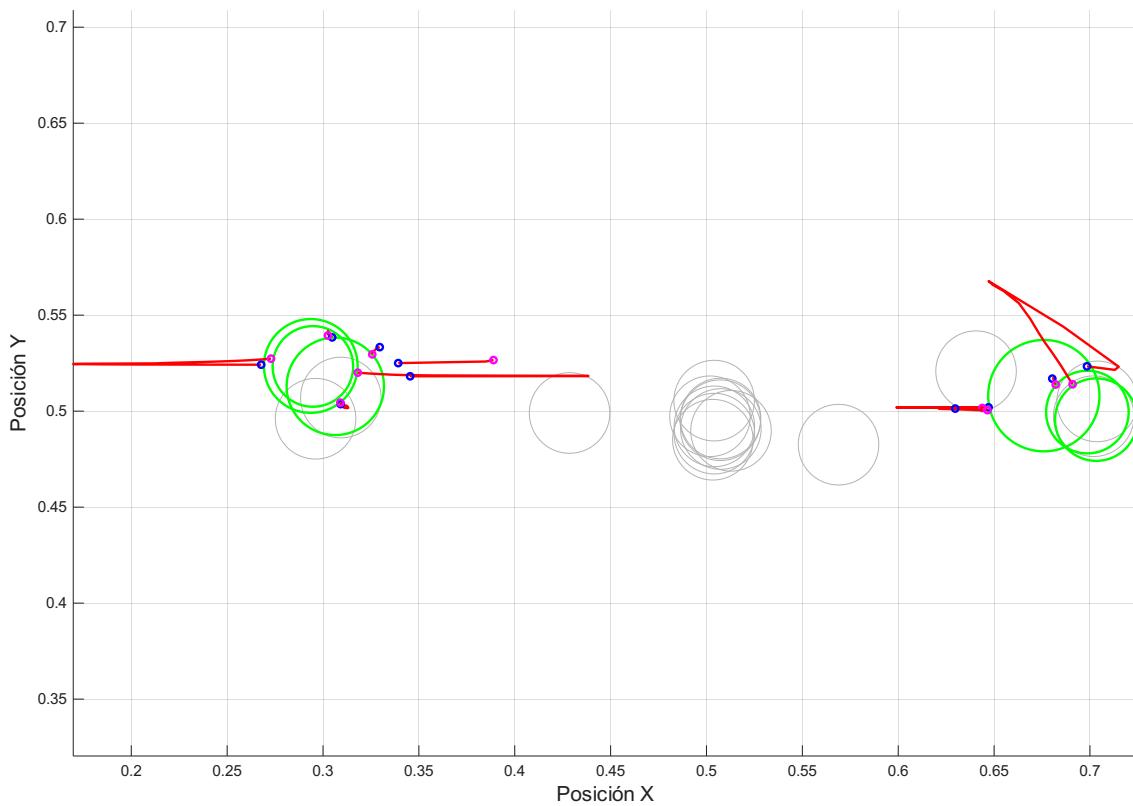


Figura 3.18: Ejemplo de visualización de las trayectorias de *sacadas correctivas* detectadas sobre los *clusters* de fijación.

Consideraciones técnicas

La implementación computacional maneja de forma robusta casos extremos como la presencia de un único punto fuera del *cluster* o secuencias no consecutivas, aplicando criterios de agrupación temporal para asegurar la identificación correcta de eventos oculomotores genuinos. La conversión temporal considera la frecuencia de muestreo específica del sistema de *eye-tracking*, garantizando precisión en las mediciones de duración. Se recomienda



interpretar las *sacadas correctivas* en conjunto con otros parámetros oculomotores para una caracterización integral del control visual.

En síntesis, las *sacadas correctivas* son un parámetro esencial para la evaluación cuantitativa de la precisión y adaptabilidad del sistema oculomotor, aportando valor diagnóstico y comparativo en estudios de función visual y envejecimiento.

3.6.3 Coeficiente de anticipación y retraso

Definición y relevancia clínica

El *coeficiente de anticipación y retraso* cuantifica la relación temporal entre el inicio de las fijaciones oculares y la aparición de los estímulos visuales, proporcionando una medida objetiva de la capacidad predictiva y de control temporal del sistema oculomotor. Su relevancia clínica reside en su sensibilidad para detectar alteraciones en la sincronización temporal de la atención visual, lo que lo convierte en un biomarcador útil en el estudio de procesos de envejecimiento y trastornos neurodegenerativos [9, 21, 35].

Fundamentos teóricos

La conceptualización de este parámetro se fundamenta en evidencia neurocientífica que indica que el sistema oculomotor posee capacidades predictivas que permiten anticipar la aparición de estímulos en tareas de seguimiento visual. Barnes (2008) documentó que el sistema visual puede generar movimientos anticipatorios basados en la predicción de trayectorias de estímulos móviles [4]. Además, Eckstein et al. (2017) demostraron que las diferencias en la sincronización temporal entre la atención visual y la aparición de estímulos reflejan variaciones en la eficiencia del procesamiento cognitivo y la capacidad de control ejecutivo [12]. El envejecimiento y los procesos neurodegenerativos pueden afectar significativamente estos mecanismos temporales [41].

Metodología de cálculo

El cálculo del *coeficiente de anticipación y retraso* se basa en la diferencia temporal entre el inicio de la fijación ocular más próxima y la aparición del estímulo visual correspondiente. Matemáticamente, se expresa como:

$$C_{unificado} = t_{fijación} - t_{estímulo} \quad (3.4)$$

donde $t_{fijación}$ es el tiempo de inicio de la fijación más próxima espacialmente al estímulo, y $t_{estímulo}$ es el tiempo de aparición del estímulo visual. Valores negativos indican anticipación



(la fijación comienza antes del estímulo), valores positivos señalan retraso (la fijación se inicia después del estímulo) y valores cercanos a cero representan sincronización temporal óptima.

El algoritmo implementado sigue estos pasos, adaptados de Raynowska y Orquin (2018) [37]:

1. **Ventana temporal de búsqueda:** Para cada estímulo, se establece una ventana de ± 500 ms respecto a su aparición para identificar fijaciones relevantes [30].
2. **Selección de fijación relevante:** Se selecciona la fijación con menor distancia euclíadiana respecto a la posición del estímulo, aplicando el criterio de proximidad espacial de Munoz y Everling (2004) [31].
3. **Cálculo de la diferencia temporal:** Se computa la diferencia entre el inicio de la fijación seleccionada y el tiempo de aparición del estímulo, obteniendo el valor del coeficiente (3.4).
4. **Clasificación temporal:** Se establecen umbrales de ± 200 ms para categorizar las respuestas como anticipación significativa (< -200 ms), retraso significativo ($> +200$ ms) o sincronización (entre -200 ms y $+200$ ms).

Criterios de validación

La validez de cada medición se garantiza mediante criterios estrictos, siguiendo las directrices de Antoniades et al. (2013) [2]:

- Existencia de fijaciones válidas dentro de la ventana temporal.
- Proximidad espacial entre la fijación y el estímulo (distancia máxima de tolerancia).
- Exclusión de valores extremos o artefactos de medición.

Parámetros extraídos

A partir del análisis del *coeficiente de anticipación y retraso* se obtienen:

- **Distribución de coeficientes:** Vector de diferencias temporales para todos los ensayos.
- **Porcentaje de anticipaciones, retrasos y sincronizaciones:** Proporción de ensayos en cada categoría temporal.
- **Estadísticos descriptivos:** Media y desviación estándar del coeficiente en cada participante o grupo.

Visualización



La visualización gráfica del *coeficiente de anticipación y retraso* a lo largo de las secuencias experimentales permite identificar patrones individuales y grupales. En este trabajo, las respuestas de anticipación se representan en azul, los retrasos en rojo y las sincronizaciones en gris, facilitando la interpretación cualitativa de los resultados [3].

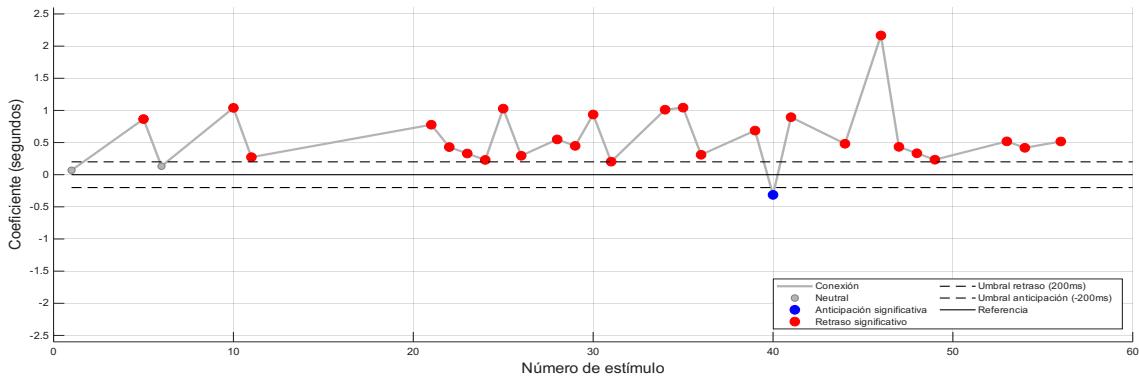


Figura 3.19: Ejemplo de visualización del *coeficiente de anticipación y retraso* frente a los estímulos visuales.

Consideraciones técnicas

La implementación computacional asegura la sincronización precisa entre los datos de fijaciones y los tiempos de estímulo, aplicando filtros de calidad y algoritmos robustos para la identificación de eventos relevantes. Esta aproximación garantiza la reproducibilidad y comparabilidad de los resultados, permitiendo su integración en estudios longitudinales y comparativos sobre envejecimiento y función cognitiva.

En conclusión, el *coeficiente de anticipación y retraso* constituye un parámetro integral para la caracterización temporal de la respuesta oculomotora, aportando valor diagnóstico y metodológico en el análisis de la atención visual y el control temporal en diferentes

3.6.4 Coeficiente de antisacadas

Definición y relevancia clínica

El *coeficiente de antisacadas* es una métrica fundamental para evaluar el control cognitivo de los movimientos oculares, específicamente la capacidad de inhibir respuestas automáticas y ejecutar movimientos oculares voluntarios. Este parámetro se deriva de la tarea de *antisacadas*, un paradigma experimental ampliamente utilizado en neurociencia cognitiva que requiere que los participantes supriman la tendencia natural de dirigir la mirada hacia un estímulo visual periférico y, en su lugar, realicen una sacada hacia la ubicación diametralmente opuesta [31]. La relevancia clínica de este parámetro radica en su



sensibilidad para detectar alteraciones en el control inhibitorio asociadas a trastornos neuropsiquiátricos y neurodegenerativos, como la esquizofrenia y la enfermedad de Alzheimer [5, 9].

Fundamentos teóricos

La tarea de *antisacadas* fue desarrollada como herramienta para evaluar el control ejecutivo y la función del córtex prefrontal [31]. Estudios como los de Benson et al. (2012) y Crawford et al. (2013) han demostrado que la tasa de errores en esta tarea constituye un biomarcador sensible de disfunción ejecutiva, relevante en el envejecimiento y los trastornos neurodegenerativos.

Metodología de cálculo

El cálculo del *coeficiente de antisacadas* se basa en el análisis de las respuestas oculomotoras durante los ensayos donde el estímulo *target* corresponde a una *antisacada* (identificados en los datos experimentales con el valor *estimulo* = 0). La metodología sigue los principios de Falck-Ytter et al. (2013) [14], adaptando los criterios de clasificación para el contexto de predicción de edad.

El algoritmo implementado sigue estos pasos principales:

1. **Identificación de ensayos de *antisacadas*:** Selección de estímulos con *estimulo* = 0.
2. **Determinación de coordenadas objetivo:** Para cada ensayo en la posición (x, y) , la posición correcta es $(x, 1 - y)$, siguiendo a Fukushima y Fukushima (2013) [15].
3. **Análisis temporal de fijaciones:** Se consideran fijaciones desde 50 ms antes del inicio del estímulo hasta 50 ms después de su finalización, según Eckstein et al. (2017) [12].
4. **Clasificación de respuestas:** Se calculan las distancias euclidianas a la posición prohibida y a la correcta. Se utiliza un umbral de 0,5 unidades normalizadas para determinar si una fijación corresponde a alguna de estas ubicaciones.
5. **Determinación de errores y aciertos:** Un ensayo es error si la mirada se dirige a la posición prohibida sin posteriormente mirar a la correcta; es acierto si se detecta al menos una fijación hacia la posición correcta, independientemente de fijaciones previas hacia la prohibida.

La tasa de error (*error rate*) se calcula como:

$$\text{Tasa de error} = \frac{N_{\text{errores}}}{N_{\text{total}}} \quad (3.5)$$



donde N_{errores} es el número de ensayos clasificados como error y N_{total} el número total de ensayos de *antisacadas*.

Criterios de validación

El criterio de validación espacial de 0,5 unidades normalizadas se fundamenta en Anderson y MacAskill (2013) [1], permitiendo una detección robusta de respuestas sacádicas. Para casos ambiguos, se aplica un umbral ampliado de 0,25 unidades normalizadas, siguiendo a Kasprowski y Harezlak (2018) [23].

Parámetros extraídos

El análisis de *antisacadas* proporciona las siguientes métricas:

- **Tasa de error:** Proporción de ensayos con respuesta incorrecta (3.5).
 - **Precisión espacial:** Vector de distancias euclidianas mínimas entre fijaciones correctas y la posición objetivo.
 - **Tiempo de predicción:** Vector con los tiempos de reacción desde el inicio del estímulo hasta la primera fijación correcta.

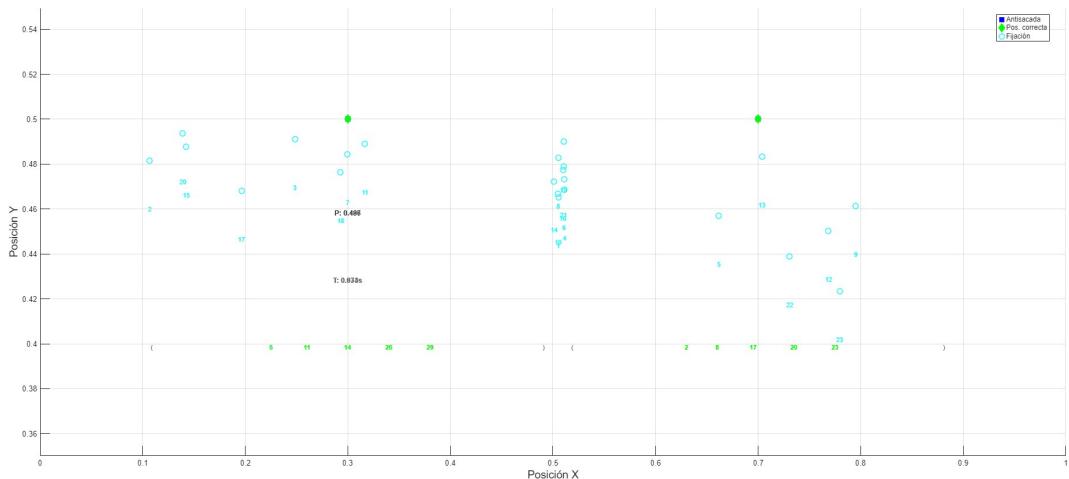


Figura 3.20: Ejemplo representativo de trayectorias oculares en la tarea de *antisacadas*.

Visualización

Consideraciones técnicas

La implementación considera respuestas correctivas, priorizando la clasificación como acierto si la fijación correcta ocurre dentro del periodo analizado, incluso si hubo fijaciones

previas hacia la posición prohibida [30]. El *coeficiente de antisacadas* resultante es una medida objetiva y cuantitativa del control inhibitorio oculomotor, correlacionada con marcadores de envejecimiento cognitivo [24] y constituye un parámetro esencial para la predicción de edad biológica en este trabajo.

3.6.5 Sacadas dobles (*Double Saccades*)

Definición y relevancia clínica

Las *sacadas dobles* constituyen un paradigma experimental especializado que evalúa la capacidad del sistema oculomotor para ejecutar secuencias rápidas y precisas de movimientos sacádicos en respuesta a estímulos visuales consecutivos [25]. Este tipo de movimientos representa un desafío particular para el control neuromotor, ya que requiere la coordinación temporal precisa de múltiples componentes del sistema de control sacádico, incluyendo la programación, ejecución y terminación de sacadas individuales dentro de una secuencia compleja. Su relevancia clínica radica en su sensibilidad para detectar alteraciones en el control temporal y la reprogramación motora, siendo útiles como biomarcadores en trastornos neurológicos y del desarrollo [27].

Fundamentos teóricos

El análisis de *sacadas dobles* permite evaluar aspectos del funcionamiento oculomotor no accesibles mediante paradigmas de sacadas simples. Este paradigma es sensible a alteraciones en el control temporal, la capacidad de reprogramación sacádica y los mecanismos de inhibición que previenen la interferencia entre sacadas consecutivas [1, 31]. La evaluación de secuencias sacádicas complejas proporciona información sobre la integridad de los circuitos cortico-subcorticales responsables del control voluntario de los movimientos oculares.

Metodología de cálculo

La detección y caracterización de *sacadas dobles* se basa en el análisis de secuencias temporales de fijaciones oculares en respuesta a la presentación de dos estímulos visuales consecutivos separados por un intervalo temporal mínimo. El algoritmo implementado sigue estos pasos:

1. **Identificación de fijación previa:** Detección de la fijación inmediatamente anterior al primer estímulo.
2. **Primera sacada:** Detección de la sacada desde la fijación previa hacia la posición del primer estímulo.
3. **Segunda sacada:** Detección de la sacada desde la posición del primer estímulo hacia la posición del segundo estímulo.



4. Fijación final:

Identificación de la fijación resultante en la posición objetivo final.

Para cada secuencia, se extraen los siguientes parámetros cuantitativos:

- **Latencia de la primera sacada (L_1)**: Tiempo desde la aparición del primer estímulo hasta el inicio de la primera sacada.
- **Latencia de la segunda sacada (L_2)**: Tiempo desde la aparición del segundo estímulo hasta el inicio de la segunda sacada.
- **Intervalo intersacádico (I)**: Tiempo entre el final de la primera sacada y el inicio de la segunda.
- **Duración de fijación previa (D_f)**: Duración de la fijación que precede a la secuencia.
- **Error de localización (E)**: Distancia euclíadiana entre la posición final de fijación y la posición objetivo del segundo estímulo.

Criterios de validación

La validación de las secuencias detectadas se realiza mediante criterios estrictos:

- Umbrales mínimos de distancia espacial entre fijaciones consecutivas.
- Rangos de latencias fisiológicamente plausibles (50–800 ms).
- Intervalos intersacádicos dentro de límites normales (0–500 ms).
- Exclusión de secuencias con fijaciones previas demasiado breves para ser detectadas (por ejemplo, < 25 ms).

Estos criterios se basan en las recomendaciones de Terao et al. (2017) [41].

Parámetros extraídos

A partir del análisis de *sacadas dobles* se obtienen:

- **Latencia de la primera sacada (L_1)**
- **Latencia de la segunda sacada (L_2)**
- **Intervalo intersacádico (I)**
- **Duración de fijación previa (D_f)**
- **Error de localización (E)**

Estos parámetros permiten evaluar la eficiencia temporal y espacial del sistema oculomotor en tareas complejas.

Visualización



La visualización incluye la representación espacial de las trayectorias oculares, la codificación cromática de diferentes tipos de fijaciones (previa, primera posición, segunda posición) y la superposición de parámetros temporales sobre las representaciones gráficas. Esta aproximación facilita la identificación de patrones anómalos y la validación manual de las detecciones automáticas.

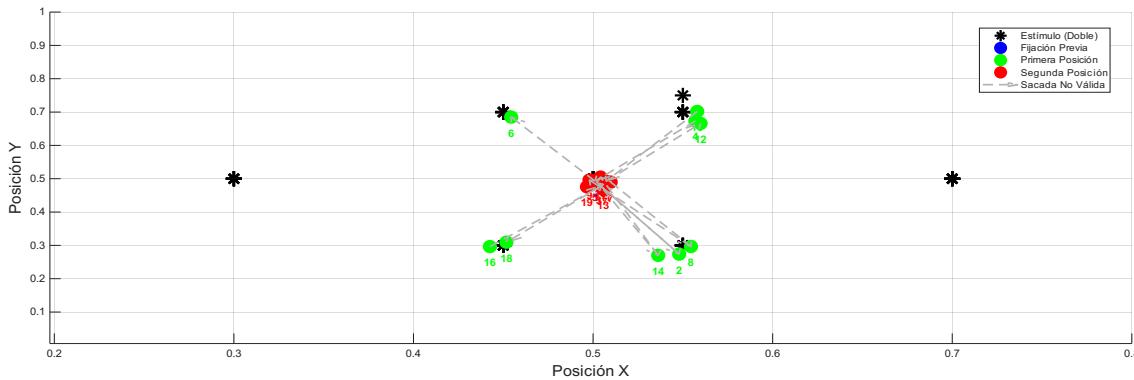


Figura 3.21: Ejemplo de visualización de una secuencia de *sacadas dobles*. En este caso, no se ha conseguido detectar la fijación previa por su brevedad (25 ms).

Consideraciones técnicas

La implementación algorítmica permite la visualización interactiva de las secuencias de *sacadas dobles*, incorpora filtros para la detección de fijaciones breves y aplica criterios de exclusión para evitar artefactos. Se recomienda interpretar los resultados en conjunto con otros parámetros oculomotores para una caracterización integral del control visual, especialmente en el contexto de alteraciones neurológicas.

En síntesis, las *sacadas dobles* son un parámetro avanzado para la evaluación de la coordinación temporal y espacial del sistema oculomotor, aportando valor diagnóstico y comparativo en estudios de función visual y

3.6.6 Seguimiento ocular suave (*Smooth Pursuit*)

Definición y relevancia clínica

El seguimiento ocular suave, o *smooth pursuit*, es un tipo especializado de movimiento ocular que permite al sistema visual mantener la fijación sobre objetos en movimiento continuo, diferenciándose de los movimientos sacádicos por su naturaleza gradual y sostenida. Su relevancia clínica radica en que las alteraciones en el *smooth pursuit* pueden reflejar disfunciones en múltiples regiones cerebrales, incluyendo la corteza visual, el cerebelo y los ganglios basales [25]. Por ello, se considera un parámetro valioso para la evaluación de procesos de envejecimiento y trastornos neurodegenerativos [1, 10].



Fundamentos teóricos

El *smooth pursuit* requiere la integración continua de información visual y procesos de control motor de alto nivel, involucrando circuitos cortico-subcorticales complejos [4]. Alteraciones en este sistema pueden manifestarse tempranamente en diversas condiciones neurológicas, precediendo incluso a síntomas clínicos evidentes [1]. El envejecimiento normal afecta sistemáticamente la calidad del seguimiento suave, deteriorando tanto la ganancia como la suavidad de las trayectorias [10].

Metodología de cálculo

El análisis cuantitativo del *smooth pursuit* se basa en el procesamiento de las señales de seguimiento ocular durante la estimulación con objetivos en movimiento continuo. El proceso se estructura en las siguientes etapas:

1. **Detección automática de intervalos de seguimiento:** Identificación de períodos de actividad de seguimiento mediante el análisis de la velocidad ocular y la aplicación de umbrales adaptativos.
2. **Cálculo de latencia de *pursuit*:** Tiempo desde el inicio del estímulo en movimiento hasta el inicio del movimiento de seguimiento, identificado mediante un umbral de velocidad mínima [41].
3. **Análisis de velocidad de seguimiento:** Cálculo de la velocidad media durante los períodos de *pursuit* activo, aplicando técnicas de suavizado para reducir el ruido.
4. **Evaluación del error de seguimiento:** Cálculo de la desviación entre la trayectoria ocular observada y una trayectoria ideal estimada, utilizando ajuste polinomial [30].
5. **Cálculo de duración del seguimiento:** Tiempo durante el cual se mantiene un seguimiento activo y coherente del estímulo.

Criterios de validación

Para garantizar la validez de los parámetros extraídos, se aplican los siguientes criterios:

- Exclusión de períodos de seguimiento con duración insuficiente o incoherencia temporal.
- Verificación de la plausibilidad fisiológica de los valores de latencia, velocidad y error.
- Validación visual de las trayectorias y parámetros calculados [2].

Parámetros extraídos

A partir del análisis del *smooth pursuit* se obtienen:

- **Latencia de inicio:** Tiempo de reacción ante el inicio del movimiento del estímulo.



- **Velocidad de seguimiento:** Velocidad media mantenida durante los períodos de *pursuit* activo.
- **Error de seguimiento:** Desviación media entre la posición ocular y la trayectoria ideal.
- **Duración del seguimiento:** Tiempo total de seguimiento activo y coherente.

Consideraciones técnicas

La implementación computacional incorpora mecanismos de validación de calidad, análisis estadístico descriptivo y visualización interactiva para la inspección manual de los resultados. Se recomienda interpretar los parámetros de *smooth pursuit* en conjunto con otras métricas oculomotoras para una caracterización integral del desempeño visual, considerando la variabilidad interindividual y el contexto experimental [3].

En síntesis, el *smooth pursuit* es un parámetro esencial para la evaluación cuantitativa de la función oculomotora continua, aportando valor diagnóstico y comparativo en estudios de envejecimiento y

3.6.7 Área envolvente convexa (*Convex Hull*)

Definición y relevancia clínica

El área envolvente convexa, conocida como *convex hull*, es una métrica geométrica que cuantifica la dispersión máxima de los movimientos oculares durante tareas de seguimiento visual. Representa el área mínima que engloba todos los puntos de fijación registrados, proporcionando una medida objetiva de la extensión espacial de la exploración visual [42]. Su relevancia clínica radica en su capacidad para detectar alteraciones en los patrones de exploración visual asociadas a condiciones neurológicas y neurodegenerativas [27, 3].

Fundamentos teóricos

El parámetro *convex hull* se fundamenta en la geometría computacional y en el análisis de la dispersión espacial de las fijaciones oculares. Toker et al. [42] demostraron que esta métrica refleja estrategias cognitivas de exploración visual, mientras que Duchowski [11] recomienda su uso para el procesamiento robusto de datos de *eye-tracking*. El área del *convex hull* complementa otras métricas como la *BCEA* y la *entropía espacial*, aportando información sobre la extensión máxima de la exploración [44].

Metodología de cálculo



El cálculo del área envolvente convexa se realiza aplicando algoritmos como *Graham* o *QuickHull* a las coordenadas normalizadas de las posiciones oculares. El área se obtiene mediante la siguiente ecuación:

$$A_{convex\ hull} = \frac{1}{2} \left| \sum_{i=1}^n (x_i y_{i+1} - x_{i+1} y_i) \right| \quad (3.6)$$

donde (x_i, y_i) son las coordenadas de los vértices del polígono convexo ordenados secuencialmente y n es el número de vértices. Esta fórmula corresponde al cálculo del área de un polígono simple mediante la regla del *shoelace*.

Criterios de validación

Para garantizar la validez del cálculo, se aplican los siguientes criterios:

- Filtrado de valores anómalos: eliminación de coordenadas con valores *NaN*, infinitos o fuera del rango normalizado [0,1].
- Verificación de un mínimo de tres puntos válidos para la construcción del polígono convexo.
- Validación visual de la envolvente convexa para descartar artefactos.

Estos procedimientos siguen las recomendaciones metodológicas de *Duchowski* [11] y aseguran la robustez del análisis.

Parámetros extraídos

A partir del análisis del *convex hull* se obtienen:

- **Área del *convex hull*:** Medida de la extensión máxima de la exploración visual.
- **Número de vértices:** Cantidad de puntos que definen el perímetro convexo.
- **Relación con otras métricas:** Comparación con *BCEA* y *entropía espacial* para caracterización integral.

Visualización

La visualización incluye la representación gráfica de los puntos de fijación y el perímetro convexo calculado. Esta funcionalidad es esencial para la validación visual y la identificación de posibles artefactos. En este trabajo, se emplean figuras donde se muestran todos los puntos válidos, el trazado del *convex hull* y el área correspondiente, siguiendo un formato homogéneo para todas las métricas espaciales.



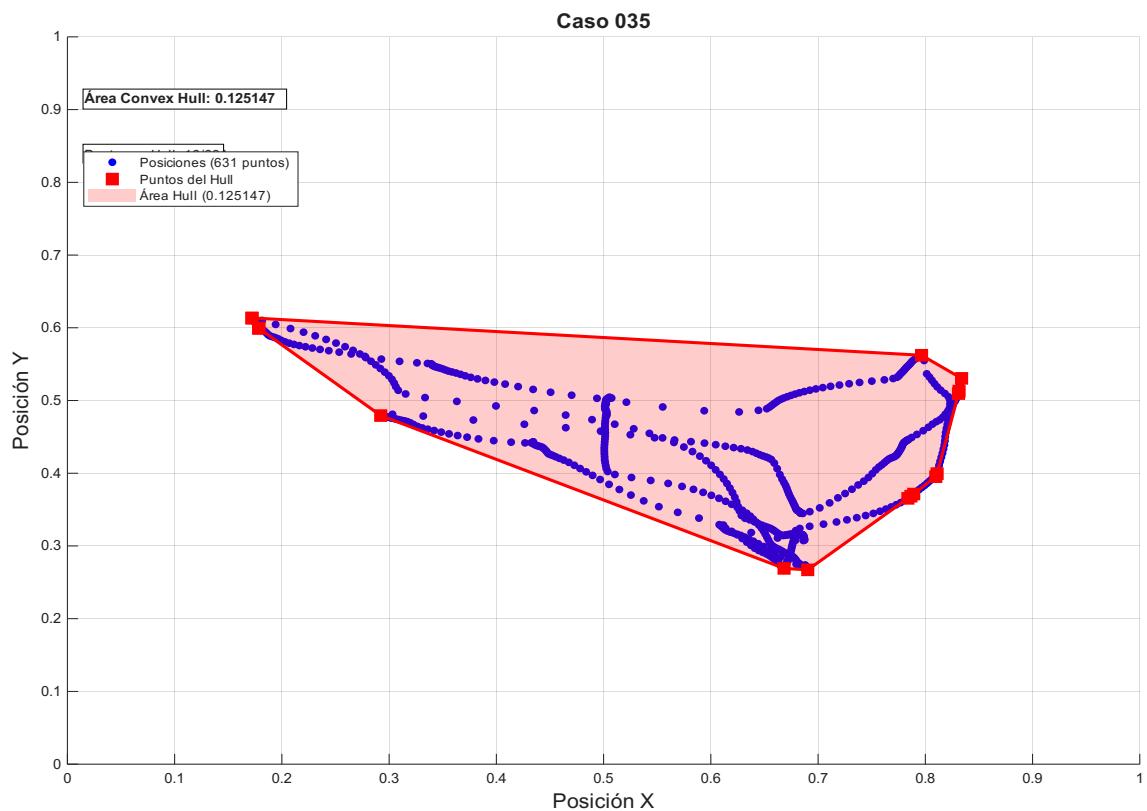


Figura 3.22: Ejemplo de visualización del área envolvente convexa (*convex hull*) superpuesta a los puntos de fijación ocular.



Consideraciones técnicas

La implementación computacional utiliza algoritmos eficientes para el cálculo del *convex hull* y aplica filtros de calidad para asegurar la validez de los datos. El análisis debe interpretarse en el contexto experimental específico: valores elevados pueden indicar una exploración visual amplia o mayor variabilidad oculomotora, mientras que valores bajos pueden reflejar una exploración más concentrada o restricciones funcionales. Se recomienda analizar esta métrica junto con otras medidas oculomotoras para una caracterización completa del comportamiento visual.

En síntesis, el área envolvente convexa (*convex hull*) es un parámetro esencial para la evaluación cuantitativa de la dispersión espacial en el análisis de movimientos oculares, aportando valor diagnóstico y comparativo en estudios de función oculomotora.

3.6.8 Área Elíptica Bivariada de Contorno (*BCEA*)

Definición y relevancia clínica

El *Bivariate Contour Ellipse Area* (*BCEA*) es una métrica estadística que cuantifica la dispersión espacial de las posiciones oculares durante períodos de fijación, proporcionando una medida objetiva de la precisión de fijación ocular [44]. Su relevancia clínica radica en su sensibilidad para detectar alteraciones en la estabilidad de la fijación, lo que la convierte en un biomarcador útil en el estudio de patologías neurodegenerativas y trastornos del desarrollo [30, 1].

Fundamentos teóricos

El parámetro *BCEA* se fundamenta en el análisis de la distribución bivariada de las posiciones oculares, asumiendo una distribución normal multivariante. Esta aproximación permite caracterizar tanto la magnitud como la orientación de la dispersión ocular, capturando la inestabilidad de la fijación [44]. El *BCEA* representa el área de la elipse que contiene aproximadamente el 68 % de las muestras de posición ocular.

Metodología de cálculo

El cálculo del *BCEA* se realiza mediante la siguiente ecuación:

$$BCEA = 2\pi\sigma_x\sigma_y\sqrt{1 - \rho^2} \quad (3.7)$$

donde σ_x y σ_y son las desviaciones estándar de las coordenadas horizontales y verticales, respectivamente, y ρ es el coeficiente de correlación entre ambas dimensiones espaciales.



Esta fórmula estima el área de la elipse de dispersión para un nivel de confianza del 68 %. Para otros niveles de confianza, el factor multiplicativo puede ajustarse (por ejemplo, $k = 2,291$ para el 95 % de los datos).

Criterios de validación

La validez del cálculo del *BCEA* depende de una adecuada identificación de períodos de fijación y de la calidad de los datos. Se aplican algoritmos de filtrado para eliminar artefactos, valores atípicos y muestras no fisiológicas, siguiendo las recomendaciones de Hessels et al. [18]. Además, la robustez del *BCEA* frente a outliers moderados y su invarianza ante transformaciones de coordenadas han sido documentadas por Bargary et al. [3].

Parámetros extraídos

A partir del análisis de *BCEA* se obtienen:

- ***BCEA***: Área de la elipse de dispersión para cada período de fijación.
- **Orientación y dimensiones de la elipse**: Calculadas a partir de la matriz de covarianza, eigenvalores y eigenvectores.
- **Estadísticos descriptivos**: Media y desviación estándar de *BCEA* en diferentes condiciones o grupos.

Visualización

La visualización de la elipse de dispersión sobre los datos de posición ocular facilita la interpretación cualitativa de la estabilidad de la fijación. En este trabajo, se emplean representaciones gráficas donde la elipse característica se superpone a las muestras de fijación, permitiendo identificar patrones anómalos o diferencias entre grupos.

Consideraciones técnicas

La implementación computacional del *BCEA* en este trabajo asegura la reproducibilidad y precisión de los cálculos mediante la aplicación de criterios estrictos de calidad de datos y el uso de algoritmos numéricamente estables para el cálculo de la matriz de covarianza. La metodología empleada permite la comparación directa con estudios previos y la interpretación clínica de los resultados, especialmente en el contexto del envejecimiento y los trastornos neurodegenerativos [21, 35].

En resumen, el *BCEA* constituye un parámetro esencial para la caracterización cuantitativa de la estabilidad de la fijación ocular, aportando valor diagnóstico y comparativo en estudios de función oculomotora.



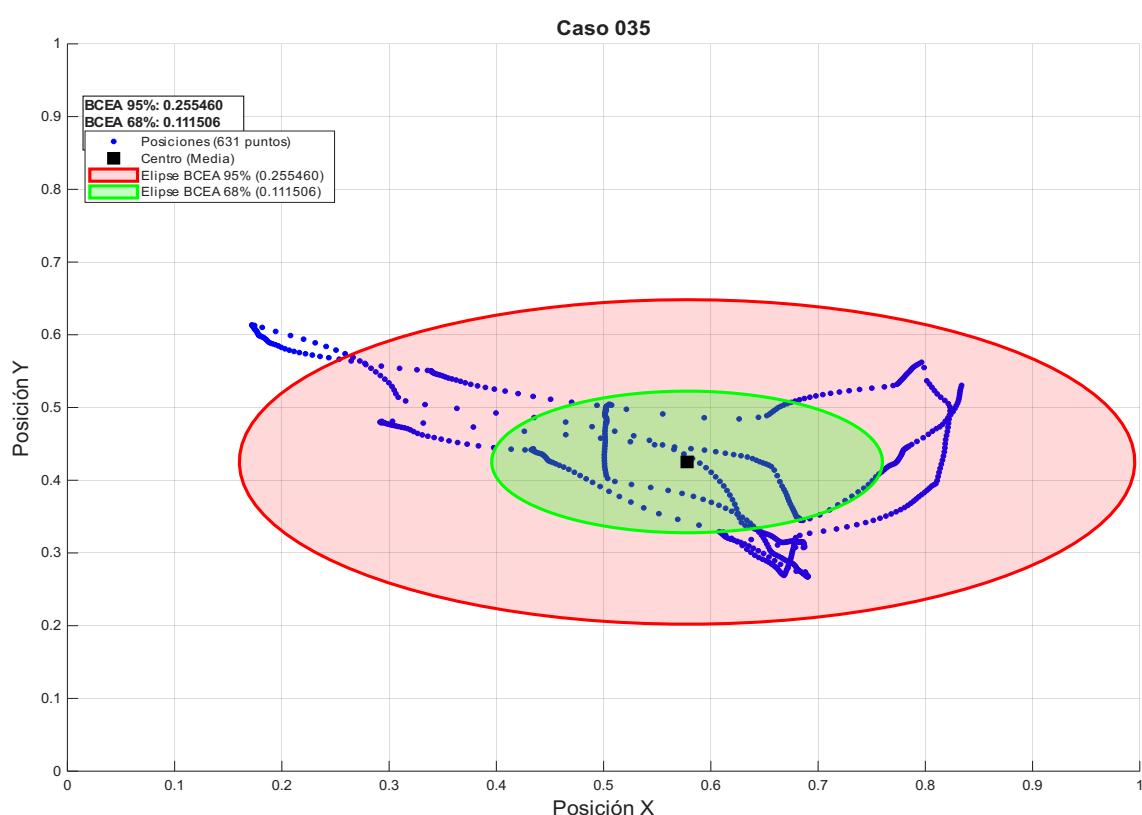


Figura 3.23: Ejemplo de visualización de la elipse de dispersión (BCEA) superpuesta a las posiciones oculares durante la fijación.



3.6.9 Distancia cuadrática media al centro (*Root Mean Square Distance, RMS-dist*)

Definición y relevancia clínica

La *distancia cuadrática media al centro* (*Root Mean Square distance, RMS-dist*) es un parámetro fundamental para la caracterización de la dispersión espacial de las fijaciones oculares durante tareas de visualización libre. Este índice cuantifica la variabilidad posicional de las muestras de seguimiento ocular respecto al baricentro o centro de masa de la distribución espacial de las fijaciones [45]. Su relevancia clínica radica en su capacidad para discriminar entre patrones de exploración visual concentrados y dispersos, proporcionando información sobre el control oculomotor y la eficiencia del procesamiento visual [42].

Fundamentos teóricos

El cálculo de la *RMS-dist* se fundamenta en la teoría de momentos estadísticos aplicada a la distribución espacial de las fijaciones oculares. Xu et al. [45] demostraron la utilidad de este parámetro como biomarcador en trastornos neurológicos que afectan el control oculomotor. Valores bajos de *RMS-dist* indican una mirada concentrada en regiones específicas del campo visual, mientras que valores elevados sugieren una exploración más dispersa o errática.

Metodología de cálculo

El cálculo de la *RMS-dist* sigue estos pasos:

- Filtrado de datos válidos:** Eliminación de muestras con valores no numéricos (*NaN*), infinitos (*Inf*) o fuera del rango normalizado [0, 1].
- Cálculo del baricentro:** Determinación del centro de masa de la distribución espacial mediante:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (3.8)$$

donde n es el número de muestras válidas.

- Cálculo de distancias euclidianas:** Para cada muestra válida, se calcula la distancia euclídea al baricentro:

$$d_i = \sqrt{(x_i - \bar{x})^2 + (y_i - \bar{y})^2} \quad (3.9)$$



4. **Cálculo de la *RMS-dist*:** La distancia cuadrática media se obtiene mediante:

$$RMS\text{-}dist = \sqrt{\frac{1}{n} \sum_{i=1}^n d_i^2} \quad (3.10)$$

En las ecuaciones anteriores, x_i y y_i son las coordenadas de cada fijación, \bar{x} y \bar{y} el baricentro, d_i la distancia de cada punto al centro y n el número de muestras válidas.

Criterios de validación

Para garantizar la validez del cálculo, se aplican los siguientes criterios:

- Presencia de al menos dos puntos válidos para el cálculo.
- Filtrado de datos atípicos y verificación de integridad de las coordenadas.
- Restricción a coordenadas normalizadas en el rango $[0, 1]$.

Estos procedimientos siguen las recomendaciones metodológicas de Toker et al. [42].

Parámetros extraídos

A partir del análisis de la *RMS-dist* se obtienen:

- **Valor de *RMS-dist*:** Medida global de la dispersión espacial de las fijaciones.
- **Distribución de distancias:** Vector de distancias individuales para análisis intra- e inter-sujeto.

Visualización

La visualización incluye la representación gráfica de la distribución espacial de las fijaciones, la ubicación del baricentro y un círculo representativo del valor de *RMS-dist*. Esta visualización facilita la interpretación clínica al permitir la evaluación visual inmediata de la concentración o dispersión de los patrones de fijación.

Consideraciones técnicas

La implementación computacional incorpora mecanismos robustos de validación de datos y manejo de errores, así como categorización automática de los patrones de concentración visual. Se recomienda interpretar la *RMS-dist* en conjunto con otros parámetros oculomotores para una caracterización integral del comportamiento visual, especialmente en el contexto del envejecimiento y los trastornos neurodegenerativos [10, 35].



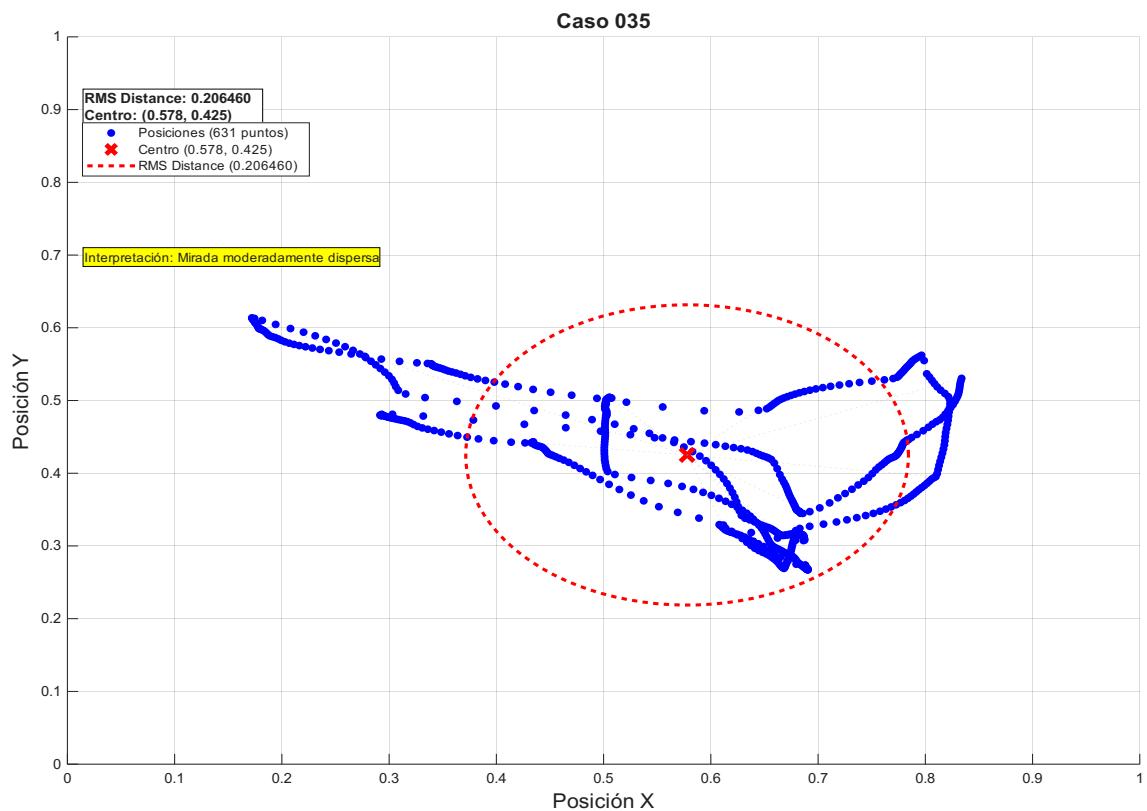


Figura 3.24: Ejemplo de visualización de la distribución de fijaciones, baricentro y círculo de radio *RMS-dist*.



En síntesis, la *distancia cuadrática media al centro* es un parámetro esencial para la evaluación cuantitativa de la dispersión espacial en el análisis de movimientos oculares, aportando valor diagnóstico y comparativo en estudios de

3.6.10 Entropía de Shannon espacial (*Shannon Entropy*)

Definición y relevancia clínica

La *entropía de Shannon* espacial es una métrica fundamental para cuantificar la impredecibilidad y dispersión de los patrones de exploración visual, midiendo la incertidumbre asociada a la localización de las fijaciones oculares en el espacio visual [34]. Su relevancia clínica reside en su capacidad para detectar alteraciones en la distribución espacial de la mirada, lo que la convierte en un biomarcador potencial en el estudio de trastornos neurodegenerativos y diferencias individuales en estrategias de exploración visual [24, 3].

Fundamentos teóricos

Este parámetro se deriva de la teoría de la información de *Shannon*, que permite evaluar la distribución espacial de las posiciones oculares mediante la cuantificación de la incertidumbre o aleatoriedad en la localización de la siguiente fijación. Valores elevados de entropía indican patrones de exploración visual impredecibles y dispersos, mientras que valores bajos reflejan comportamientos más focalizados o estereotipados.

Metodología de cálculo

El cálculo de la *entropía de Shannon* espacial se basa en la discretización del plano visual en una cuadrícula regular de $n \times n$ celdas. El número de *bins* se determina mediante una regla de Sturges modificada, adaptando la resolución espacial al número de muestras disponibles:

$$n_{bins} = \max(5, \min(50, \lfloor \sqrt{n_{puntos}} \rfloor)) \quad (3.11)$$

donde n_{puntos} es el número total de muestras válidas.

La probabilidad de ocupación de cada celda (i, j) se calcula como:

$$P_{(i,j)} = \frac{n_{i,j}}{N_{total}} \quad (3.12)$$

donde $n_{i,j}$ es el número de muestras en la celda (i, j) y N_{total} el total de muestras válidas.

La *entropía de Shannon* espacial se define como:

$$H_{\text{spatial}} = - \sum_{k=1}^M p_k \log_2(p_k) \quad (3.13)$$

donde p_k es la probabilidad de ocupación de la celda k (considerando solo celdas con $p_k > 0$ para evitar la indefinición de $\log_2(0)$) y M es el número total de celdas ocupadas.

Criterios de validación

Para garantizar la validez del cálculo, se aplican los siguientes criterios:

- Filtrado de valores no válidos (*NaN*, *Inf*) y restricción a coordenadas normalizadas en el rango [0, 1].
- Selección adaptativa del número de *bins* para asegurar robustez estadística.
- Exclusión de celdas vacías en el cálculo de la entropía.

Estos procedimientos siguen las recomendaciones metodológicas de *Duchowski* [11] y *Mathôt* [29].

Parámetros extraídos

A partir del análisis de la *entropía de Shannon* espacial se obtienen:

- **Valor de entropía:** Medida global de la dispersión espacial de las fijaciones.
- **Mapa de densidad:** Distribución espacial de la probabilidad de ocupación de cada celda.

Visualización

La visualización de los resultados se realiza mediante mapas de calor (*heatmaps*) que representan la densidad de muestras en cada celda de la cuadrícula, facilitando la interpretación intuitiva de los patrones espaciales identificados. Esta representación gráfica permite la identificación visual de regiones de interés preferencial y la evaluación cualitativa de la heterogeneidad en la distribución espacial de las fijaciones oculares.

Consideraciones técnicas

La selección adecuada del número de *bins* es crítica para evitar tanto la sobresegmentación como la pérdida de resolución espacial. La implementación computacional incorpora filtros de calidad y validación visual para asegurar la robustez y reproducibilidad de los resultados. Se recomienda interpretar la *entropía de Shannon* espacial en conjunto con otras

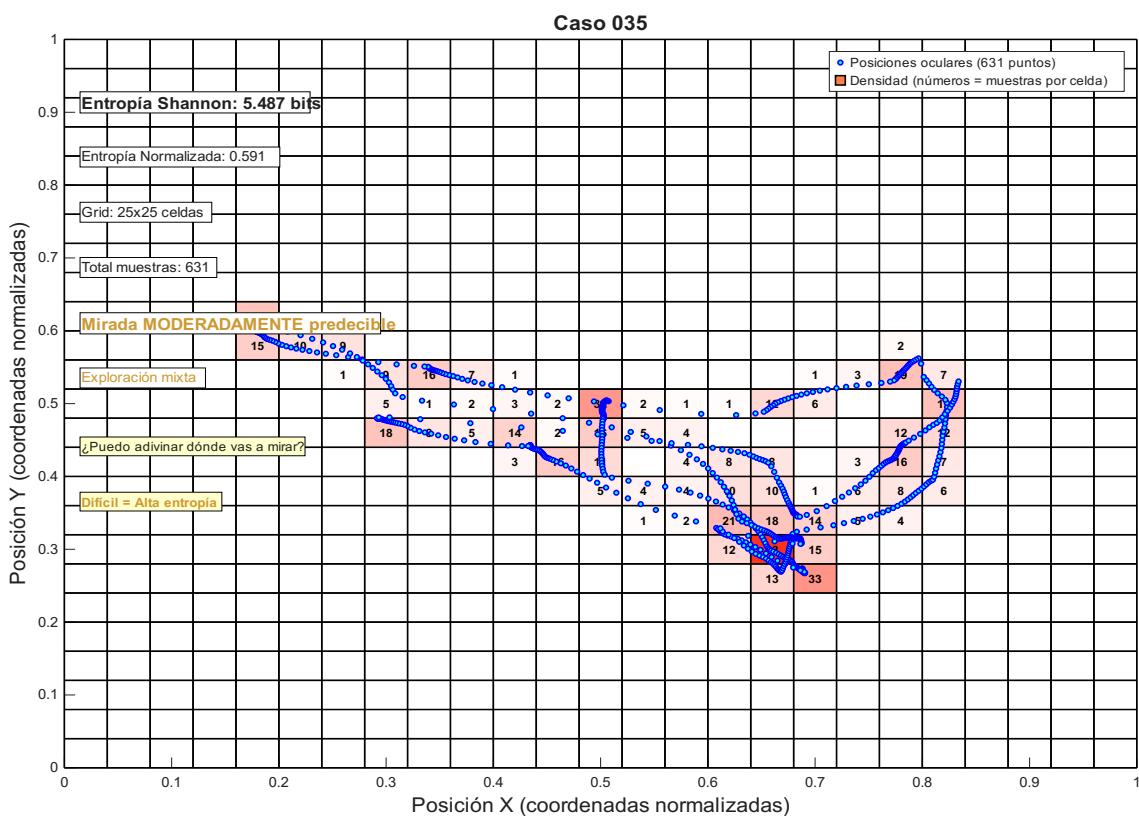


Figura 3.25: Ejemplo de visualización del mapa de calor y valor de *entropía de Shannon* espacial para un conjunto de fijaciones oculares.



métricas oculomotoras para una caracterización integral de los patrones de exploración visual.

En síntesis, la *entropía de Shannon* espacial es un parámetro esencial para la evaluación cuantitativa de la dispersión y predictibilidad en el análisis de movimientos oculares, aportando valor diagnóstico y comparativo en estudios

3.6.11 Entropía de Muestra (*Sample Entropy*) del radio temporal

Definición y relevancia clínica

La *Sample Entropy* del radio temporal es un parámetro avanzado que cuantifica la complejidad temporal de los patrones oculomotores durante tareas de fijación. Evalúa la irregularidad en la serie temporal de la distancia al centroide de las fijaciones, proporcionando una medida objetiva de la variabilidad temporal del control oculomotor. Su relevancia clínica radica en su capacidad para detectar alteraciones en la regularidad de los movimientos oculares, lo que la convierte en un biomarcador potencial en el estudio de trastornos neurológicos y del desarrollo [39].

Fundamentos teóricos

El concepto de *Sample Entropy* fue introducido por Richman y Moorman [39] como una medida robusta de la regularidad de series temporales fisiológicas. A diferencia de otras métricas de entropía, la *SampEn* es menos sensible a la longitud de la serie y al ruido. En el contexto oculomotor, su aplicación al radio temporal permite evaluar la estabilidad del control postural ocular: valores altos indican mayor irregularidad y potencial ineficiencia, mientras que valores bajos sugieren patrones regulares y predecibles.

Metodología de cálculo

El cálculo de la *SampEn* del radio temporal sigue estos pasos:

1. **Cálculo del centroide:** Se obtiene el centroide de las posiciones de fijación como $x_c = \frac{1}{N} \sum_{i=1}^N x_i$ y $y_c = \frac{1}{N} \sum_{i=1}^N y_i$, donde N es el número de muestras válidas.
2. **Serie temporal del radio:** Se calcula $r(t) = \sqrt{(x(t) - x_c)^2 + (y(t) - y_c)^2}$, que representa la distancia euclíadiana instantánea de cada posición ocular al centroide.
3. **Cálculo de la *Sample Entropy*:** Se utiliza la ecuación

$$\text{SampEn}(m, r) = -\ln \left(\frac{A}{B} \right) \quad (3.14)$$



donde A es el número de pares de patrones de longitud $m + 1$ que cumplen la condición de similitud, y B es el número de pares de patrones de longitud m similares, con tolerancia r . Los parámetros estándar recomendados son $m = 2$ y $r = 0,2 \times \sigma$, siendo σ la desviación estándar de la serie $r(t)$.

Cada variable de la ecuación (3.14) se explica así: m es la dimensión embebida, r la tolerancia, A y B los conteos de patrones similares.

Criterios de validación

Para garantizar la validez del cálculo, se aplican los siguientes criterios:

- Eliminación de muestras no válidas (NaN , infinitos o fuera del rango normalizado $[0, 1]$).
- Requiere al menos 10 muestras válidas por período de fijación para asegurar estabilidad estadística.
- Verificación de la estacionariedad de la serie temporal y detección de *outliers*.

Estos procedimientos siguen las recomendaciones metodológicas de Richman y Moorman [39] y garantizan la robustez del análisis.

Parámetros extraídos

A partir del análisis de la *SampEn* del radio temporal se obtienen:

- ***Sample Entropy***: Valor de irregularidad temporal para cada período de fijación.
- **Estadísticos descriptivos**: Media y desviación estándar de la *SampEn* en diferentes condiciones o grupos.

Visualización

La visualización incluye la representación gráfica de la serie temporal del radio y el valor de *SampEn* calculado. Esta funcionalidad facilita la identificación de patrones anómalos y la validación visual de los resultados computacionales. En este trabajo, se emplean figuras donde se muestra la evolución temporal del radio y el valor de entropía asociado, siguiendo un formato homogéneo para todas las métricas temporales.

Consideraciones técnicas

La selección de los parámetros m y r debe balancear sensibilidad y robustez ante el ruido inherente en los datos de *eye-tracking*. Se recomienda $m = 2$ y $r = 0,2 \times \sigma$ para la mayoría de aplicaciones fisiológicas. La duración mínima de los períodos de fijación es crítica para la confiabilidad estadística, y la validación debe incluir la verificación de la



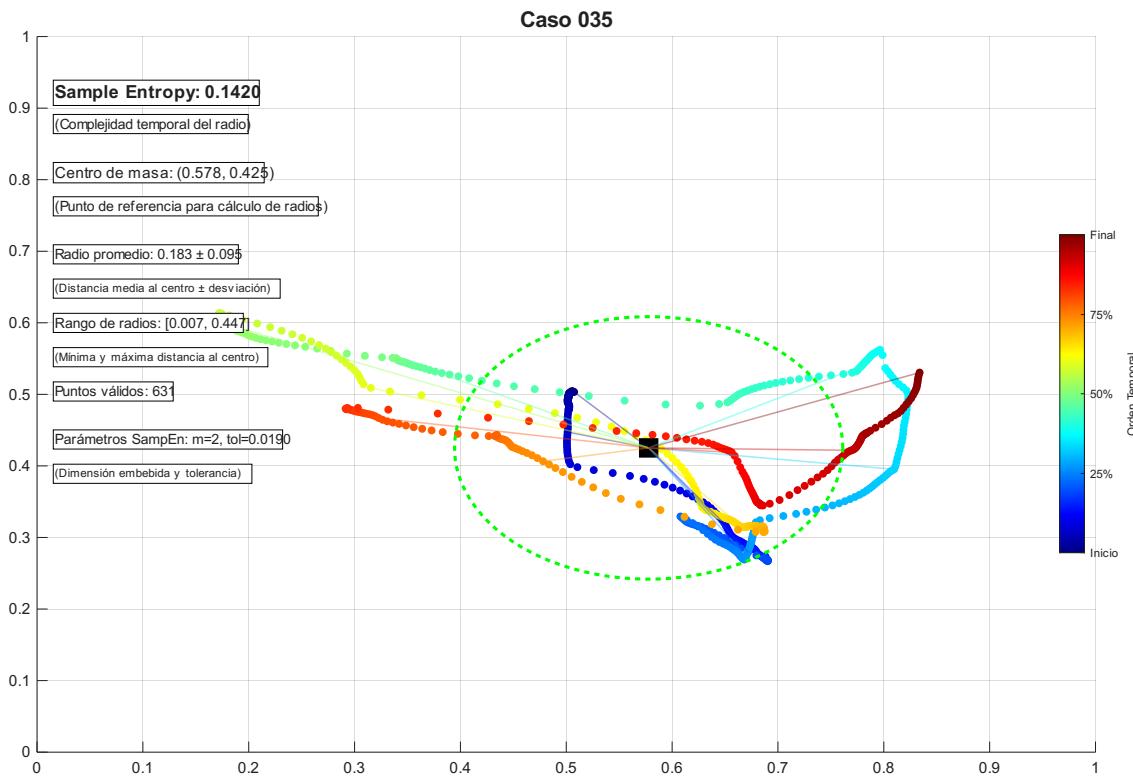


Figura 3.26: Ejemplo de visualización de la serie temporal del radio y el valor de *Sample Entropy* calculado para un período de fijación.

estacionariedad de la serie. La implementación computacional incorpora filtros adaptativos y métodos de detección de *outliers* para minimizar el impacto de artefactos experimentales.

En síntesis, la *Sample Entropy* del radio temporal es un parámetro esencial para la evaluación cuantitativa de la complejidad temporal en el análisis de movimientos oculares, aportando valor diagnóstico y comparativo en estudios de función oculomotora.

3.7 Regression Learner: Plataforma de Entrenamiento y Optimización de Modelos

La selección y optimización de algoritmos de aprendizaje automático constituye una etapa crítica en el desarrollo de modelos predictivos. Para esta tarea, se empleó Regression Learner de MATLAB, una plataforma integrada que facilita la comparación sistemática de múltiples algoritmos de regresión y la optimización de sus hiperparámetros de forma automatizada.



3.7.1 Arquitectura y Funcionalidades de Regression Learner

Regression Learner representa una interfaz unificada que permite el entrenamiento, evaluación y comparación de diferentes familias de algoritmos de regresión sin requerir implementación manual de cada método [22]. Esta plataforma integra las funcionalidades de las principales toolboxes de machine learning de MATLAB, proporcionando acceso a algoritmos que van desde modelos lineales simples hasta métodos de ensemble avanzados.

La arquitectura de la plataforma se estructura en módulos especializados que gestionan diferentes aspectos del proceso de modelado: preprocesamiento automático de datos, selección de algoritmos, optimización de hiperparámetros, validación cruzada, y evaluación de rendimiento. Esta estructura modular permite una exploración sistemática del espacio de modelos disponibles mientras mantiene la consistencia metodológica entre diferentes aproximaciones.

3.7.1.1 Algoritmos Disponibles y Clasificación

La plataforma ofrece acceso a más de 20 algoritmos de regresión organizados en cinco familias principales:

Modelos Lineales: Incluyen regresión lineal múltiple, regresión con regularización (Ridge, Lasso, Elastic Net), y regresión robusta. Estos métodos son particularmente apropiados cuando se asume una relación aproximadamente lineal entre predictores y variable respuesta, y ofrecen alta interpretabilidad [43].

Procesos Gaussianos: Proporcionan predicciones probabilísticas con estimaciones de incertidumbre, siendo particularmente valiosos cuando se requiere cuantificar la confianza en las predicciones individuales [8].

3.7.2 Procedimientos de Entrenamiento y Validación

El proceso de entrenamiento en Regression Learner sigue una metodología estandarizada que garantiza la comparabilidad entre diferentes algoritmos y la robustez de las evaluaciones de rendimiento.

3.7.2.1 Partición de Datos y Validación Cruzada

La plataforma implementa automáticamente esquemas de validación cruzada para proporcionar estimaciones no sesgadas del rendimiento del modelo. Por defecto, se utiliza validación cruzada k-fold con $k=5$, aunque este parámetro puede ajustarse según las características del dataset y los requerimientos específicos del problema.



La validación cruzada estratificada garantiza que cada fold mantenga una distribución representativa de la variable respuesta, aspecto crítico cuando se trabaja con datos de envejecimiento donde la distribución de edades puede presentar características específicas [24]. Este enfoque minimiza la varianza en las estimaciones de rendimiento y proporciona una evaluación más confiable de la capacidad de generalización del modelo.

3.7.2.2 Métricas de Evaluación

La evaluación del rendimiento se basa en múltiples métricas que capturan diferentes aspectos de la calidad predictiva:

Error Cuadrático Medio (RMSE): Proporciona una medida del error de predicción penalizando más fuertemente los errores grandes. Su interpretabilidad directa en las unidades de la variable respuesta (años en este caso) facilita la evaluación práctica del rendimiento.

Error Absoluto Medio (MAE): Menos sensible a outliers que RMSE, proporciona una medida más robusta del error típico de predicción. Particularmente relevante en aplicaciones biomédicas donde se requiere estabilidad predictiva.

Coeficiente de Determinación (R^2): Cuantifica la proporción de varianza explicada por el modelo, proporcionando una medida normalizada de la calidad del ajuste independiente de la escala de la variable respuesta.

3.7.3 Optimización de Hiperparámetros

Una de las funcionalidades más valiosas de Regression Learner es su capacidad para realizar optimización automática de hiperparámetros mediante algoritmos bayesianos avanzados.

3.7.3.1 Búsqueda Bayesiana de Hiperparámetros

La plataforma implementa optimización bayesiana que modela la función objetivo (rendimiento del modelo) como un proceso gaussiano y utiliza funciones de adquisición para dirigir la búsqueda hacia regiones prometedoras del espacio de hiperparámetros [6]. Esta aproximación es significativamente más eficiente que búsquedas exhaustivas o aleatorias, especialmente relevante cuando el espacio de hiperparámetros es de alta dimensionalidad.

El proceso iterativo de optimización bayesiana balancea exploración (evaluación de regiones no exploradas) y explotación (refinamiento cerca de configuraciones prometedoras), maximizando la probabilidad de encontrar configuraciones óptimas con un número limitado de evaluaciones.



3.7.3.2 Hiperparámetros Críticos por Familia de Algoritmos

Cada familia de algoritmos presenta hiperparámetros específicos cuya optimización es crítica para el rendimiento:

Para modelos de ensemble como Random Forest, los parámetros más influyentes incluyen el número de árboles, profundidad máxima, y número mínimo de muestras por hoja. La optimización de estos parámetros permite balancear capacidad predictiva y tiempo computacional mientras previene sobreajuste [28].

En SVM, la selección del kernel y sus parámetros asociados (como el parámetro de ancho de banda en kernels gaussianos) determina la complejidad de las fronteras de decisión que el modelo puede aprender. La optimización conjunta de estos parámetros con el parámetro de regularización es fundamental para lograr buenos resultados.

3.7.4 Estrategias de Optimización de Resultados

La maximización del rendimiento predictivo requiere considerar múltiples aspectos metodológicos que van más allá de la simple selección de algoritmos.

3.7.4.1 Preprocesamiento y Transformación de Características

Regression Learner proporciona opciones automatizadas de preprocesamiento que pueden impactar significativamente el rendimiento:

Normalización de Características: La estandarización z-score o normalización min-max garantiza que todas las características contribuyan equitativamente al proceso de aprendizaje, especialmente crítico para algoritmos sensibles a escala como SVM o k-NN.

Transformación de Variables: La aplicación de transformaciones logarítmicas o de potencia puede mejorar la linealidad de las relaciones y la normalidad de los residuos, beneficiando especialmente a modelos lineales.

Selección de Características: Aunque no implementada automáticamente, la plataforma permite evaluar el impacto de diferentes subconjuntos de características, facilitando la identificación de variables más informativas [29].

3.7.4.2 Ensemble de Modelos

Una estrategia avanzada para maximizar el rendimiento consiste en combinar predicciones de múltiples modelos. Regression Learner facilita la exportación de modelos entrenados,



permitiendo implementar estrategias de ensemble que pueden superar el rendimiento de modelos individuales.

El ensemble promedio simple combina predicciones de diferentes algoritmos asignando pesos iguales, mientras que el ensemble ponderado asigna pesos basados en el rendimiento individual de validación cruzada. Estrategias más sofisticadas como stacking utilizan un meta-modelo para aprender la combinación óptima de predicciones base.

3.7.4.3 Validación y Diagnóstico de Modelos

La plataforma proporciona herramientas de diagnóstico que permiten identificar problemas potenciales y oportunidades de mejora:

Análisis de Residuos: La inspección de patrones en los residuos puede revelar violaciones de supuestos del modelo, heterocedasticidad, o relaciones no-lineales no capturadas.

Análisis de Importancia de Características: Para algoritmos que lo soportan, la cuantificación de la importancia relativa de cada característica proporciona insights sobre los mecanismos predictivos y puede guiar refinamientos del modelo.

Detección de Sobreajuste: La comparación sistemática entre rendimiento de entrenamiento y validación permite identificar casos de sobreajuste y ajustar estrategias de regularización acordemente.

3.7.5 Consideraciones Computacionales y Escalabilidad

La selección de algoritmos debe considerar no solo la precisión predictiva sino también los requerimientos computacionales, especialmente relevante cuando se trabaja con datasets grandes o se requieren predicciones en tiempo real.

Algoritmos como regresión lineal y k-NN tienen costos computacionales predecibles y escalables, mientras que métodos como SVM con kernels no-lineales o Procesos Gaussianos pueden presentar limitaciones de escalabilidad. La plataforma proporciona estimaciones de tiempo de entrenamiento que facilitan estas decisiones.

La funcionalidad de Regression Learner de MATLAB constituye así una herramienta integral que democratiza el acceso a técnicas avanzadas de machine learning mientras mantiene rigor metodológico. Su capacidad para automatizar aspectos técnicos complejos permite concentrarse en decisiones científicas fundamentales, optimizando el proceso de desarrollo de modelos predictivos robustos y confiables.



CAPÍTULO 4

RESULTADOS Y DISCUSIÓN

↑

4.1 Resultados	71
4.2 Discusión de los resultados	89

4.1 Resultados

4.1.1 Correlaciones de los parámetros con la edad

A continuación se muestra en las tablas 4.3, 4.1 y 4.2 las correlaciones de los parámetros oculomotores con la edad, expresadas en términos de coeficiente de correlación de Pearson (r) y su significancia estadística (p). Además, en las figuras 4.2 y 4.1 se ilustra visualmente la relación entre algunos de estos parámetros y la edad, mostrando ejemplos representativos de la tendencia observada en los datos.

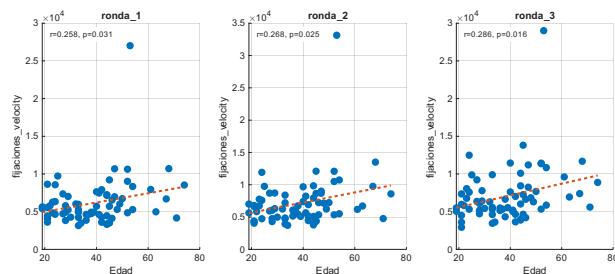


Figura 4.1: Relación entre la Velocidad de Fijaciones (Exp. 2) y la edad.

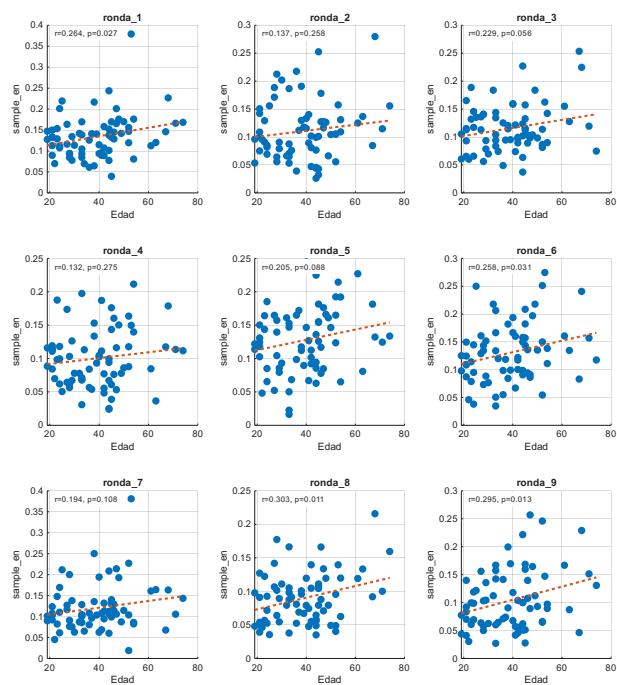


Figura 4.2: Relación entre la Entropía de Muestra (Exp. 7) y la edad.



Tabla 4.1: Correlaciones de los parámetros Ganancia de Sacadas, Sacadas Correctivas, Coeficiente de Anticipación, Coeficiente de Retraso y Antisacadas. Valores de r y p para cada ronda \mathbf{R} y tamaño de muestra \mathbf{N} .

Parámetro	Exp.	R	N	Correlación	
				r	p
Ganancia de Sacadas	2	1	70	0.049	0.687
		2	68	-0.046	0.708
		3	70	-0.049	0.687
	3	1	68	0.112	0.361
		2	66	0.182	0.143
		3	65	0.061	0.631
	4	1	65	-0.290	0.019
		2	68	0.102	0.409
		3	68	-0.054	0.662
	5	1	69	0.150	0.217
		2	67	0.112	0.367
		3	65	-0.016	0.902
	8	1	62	-0.138	0.284
		2	65	-0.173	0.169
		3	61	0.010	0.940
Sacadas Correctivas: Duraciones	2	1	35	0.203	0.241
		2	39	0.138	0.402
		3	31	0.203	0.273
	3	1	4	-0.462	0.538
		2	10	0.421	0.226
		3	7	-0.228	0.624
	4	1	42	-0.210	0.181
		2	30	-0.183	0.332
		3	36	-0.025	0.884
	8	1	33	-0.408	0.018
		2	35	-0.216	0.213
		3	15	-0.212	0.448
Coeficiente de Retraso	2	1	70	-0.040	0.740
		2	69	-0.108	0.377
		3	70	-0.145	0.231
	3	1	69	-0.070	0.565
		2	70	0.208	0.084
		3	69	-0.025	0.837
	4	1	68	-0.067	0.590
		2	69	-0.021	0.865
		3	68	-0.106	0.391
	8	1	66	-0.103	0.410
		2	70	-0.031	0.802
		3	69	0.127	0.300
Antisacadas: Precisión Espacial	2	1	35	0.188	0.280
		2	39	0.049	0.768
		3	31	0.183	0.325
	3	1	4	-0.773	0.227
		2	10	0.290	0.416
		3	7	-0.069	0.883
	4	1	42	-0.073	0.648
		2	30	-0.201	0.288
		3	36	-0.064	0.712
	8	1	33	-0.412	0.017
		2	35	-0.125	0.474
		3	15	-0.156	0.580
Coeficiente de Anticipación	2	1	19	-0.199	0.414
		2	16	-0.483	0.058
		3	18	-0.070	0.782
	3	1	51	0.151	0.291
		2	56	0.200	0.139
		3	47	-0.193	0.193
	4	1	26	0.199	0.329
		2	20	-0.371	0.107
		3	24	0.053	0.808
	8	1	11	-0.443	0.172
		2	10	0.383	0.275
		3	9	-0.318	0.404
Antisacadas: Tiempo de Predicción	2	1	68	-0.183	0.135
		2	68	0.093	0.452
		3	68	0.084	0.494
	3	1	68	-0.049	0.691
		2	68	0.123	0.318
		3	68	-0.081	0.513



Tabla 4.2: Correlaciones de los parámetros Envolvente Convexa, Distancia RMS, Área Elíptica Bivariada 68 % y del 95 %, Entropía de Shannon y de Muestra. Valores de r y p para cada ronda \mathbf{R} y tamaño de muestra \mathbf{N} .

Parámetro	Exp.	R	N	Correlación	
				r	p
Envolvente Convexa (Convex Hull)	7	1	70	0.007	0.957
		2	70	-0.152	0.208
		3	70	0.113	0.351
		4	70	-0.015	0.900
		5	70	-0.001	0.993
		6	70	0.141	0.245
		7	70	0.028	0.816
		8	70	0.024	0.845
		9	70	-0.166	0.169

Parámetro	Exp.	R	N	Correlación	
				r	p
Distancia RMS (Root Mean Square)	7	1	70	-0.146	0.227
		2	70	-0.112	0.358
		3	70	0.037	0.760
		4	70	-0.052	0.670
		5	70	-0.081	0.503
		6	70	0.065	0.595
		7	70	-0.077	0.527
		8	70	0.016	0.897
		9	70	-0.122	0.313

Parámetro	Exp.	R	N	Correlación	
				r	p
Área Elíptica Bivariada 68 %	7	1	70	-0.142	0.242
		2	70	-0.162	0.180
		3	70	0.042	0.733
		4	70	-0.050	0.679
		5	70	-0.022	0.854
		6	70	0.032	0.794
		7	70	-0.081	0.508
		8	70	-0.009	0.941
		9	70	-0.123	0.309

Parámetro	Exp.	R	N	Correlación	
				r	p
Área Elíptica Bivariada 95 %	7	1	70	-0.142	0.242
		2	70	-0.162	0.180
		3	70	0.042	0.733
		4	70	-0.050	0.679
		5	70	-0.022	0.854
		6	70	0.032	0.794
		7	70	-0.081	0.508
		8	70	-0.009	0.941
		9	70	-0.123	0.309

Parámetro	Exp.	R	N	Correlación	
				r	p
Entropía de Shannon	7	1	70	0.044	0.717
		2	70	0.073	0.547
		3	70	0.219	0.069
		4	70	0.039	0.749
		5	70	0.024	0.842
		6	70	0.272	0.023
		7	70	0.001	0.994
		8	70	0.170	0.159
		9	70	0.023	0.849

Parámetro	Exp.	R	N	Correlación	
				r	p
Entropía de Muestra	7	1	70	0.264	0.027
		2	70	0.137	0.258
		3	70	0.229	0.056
		4	70	0.132	0.275
		5	70	0.205	0.088
		6	70	0.258	0.031
		7	70	0.194	0.108
		8	70	0.303	0.011
		9	70	0.295	0.013



Tabla 4.3: Correlaciones de los parámetros Smooth Pursuit: Velocidades, Errores de Seguimiento y Duraciones de Pursuit; Velocidades y número de fijaciones. Valores de r y p para cada ronda \mathbf{R} y tamaño de muestra \mathbf{N} .

Parámetro	Exp.	R	N	Correlación		Parámetro	Exp.	R	N	Correlación	
				r	p					r	p
Velocidad de Fijaciones	1	1	70	0.152	0.208	Número de Fijaciones	1	1	70	-0.175	0.147
		1	70	0.258	0.031		1	70	-0.194	0.107	
	2	2	70	0.268	0.025		2	2	-0.261	0.029	
		3	70	0.286	0.016		3	70	-0.279	0.019	
		1	70	0.286	0.017		1	70	-0.259	0.030	
	3	2	70	0.308	0.010		3	2	-0.224	0.063	
		3	70	0.298	0.012		3	70	-0.221	0.066	
		1	70	0.222	0.064		1	70	-0.264	0.027	
	4	2	70	0.189	0.117		4	2	-0.124	0.305	
		3	70	0.224	0.063		3	70	-0.265	0.027	
		1	70	0.336	0.004		1	70	-0.275	0.021	
	5	2	70	0.265	0.027		5	2	-0.283	0.018	
		3	70	0.204	0.090		3	70	-0.242	0.043	
8	1	70	0.265	0.027		8	1	70	-0.274	0.022	
	2	70	0.269	0.024			2	70	-0.325	0.006	
		3	70	0.284	0.017		3	70	-0.332	0.005	

Parámetro	Exp.	R	N	Correlación	
				r	p
Smooth Pursuit: Velocidades	6	1	70	0.185	0.125
		2	70	0.219	0.068
		3	70	-0.059	0.626
Smooth Pursuit: Errores de Seguimiento	6	1	70	0.118	0.332
		2	70	0.098	0.421
		3	70	-0.034	0.780
Smooth Pursuit: Duraciones de Pursuit	6	1	70	-0.030	0.806
		2	70	0.062	0.609
		3	70	0.050	0.683



4.1.2 Matriz de correlación entre parámetros oculomotores

Para explorar las relaciones entre los distintos parámetros extraídos, se presenta a continuación la matriz de correlación de Pearson entre todos los parámetros calculados, dividida en cuatro cuadrantes para facilitar su visualización. Esta matriz permite identificar grupos de variables altamente relacionadas y posibles redundancias en los datos.

En la siguiente tabla se resumen las correlaciones más altas observadas entre pares de parámetros. Se observa que muchas de las correlaciones más elevadas corresponden a parámetros derivados de una misma métrica o de métricas muy relacionadas, lo que indica una fuerte redundancia entre ellos.

Tabla 4.4: Principales correlaciones entre parámetros ($|r| > 0,9$).

Parámetro 1	Parámetro 2	Experimento	r	n
Exp7_bcea_68_R1	Exp7_bcea_95_R1	7	1.000	70
Exp7_bcea_68_R3	Exp7_rms_distance_R3	7	0.985	70
Exp4_sacadas_correctivas_max_distances_R3	Exp4_sacadas_correctivas_durations_R3	4	0.957	36
Exp2_fijaciones_velocity_R1	Exp2_fijaciones_velocity_R2	2	0.954	70
Exp8_sacadas_correctivas_max_distances_R1	Exp8_sacadas_correctivas_durations_R1	8	0.942	33
Exp1_fijaciones_velocity_R1	Exp1_fijaciones_numero_R1	1	-0.918	70
Exp3_fijaciones_velocity_R2	Exp4_fijaciones_velocity_R1	3-4	0.906	70

Como puede observarse, las correlaciones perfectas ($r = 1,000$) se dan entre los parámetros *bcea_68* y *bcea_95* del mismo experimento y ronda, lo que indica que ambos miden esencialmente la misma característica con diferente umbral. También destacan correlaciones muy altas entre métricas de dispersión espacial (*bcea*, *rms_distance*, *convex_hull*) y entre repeticiones de un mismo parámetro, así como entre parámetros derivados de la misma señal (por ejemplo, velocidad y número de fijaciones, con correlación negativa). Esto sugiere que existe redundancia entre algunos parámetros y que, para futuros análisis, podría considerarse una reducción de la dimensionalidad o la selección de un subconjunto representativo de variables.



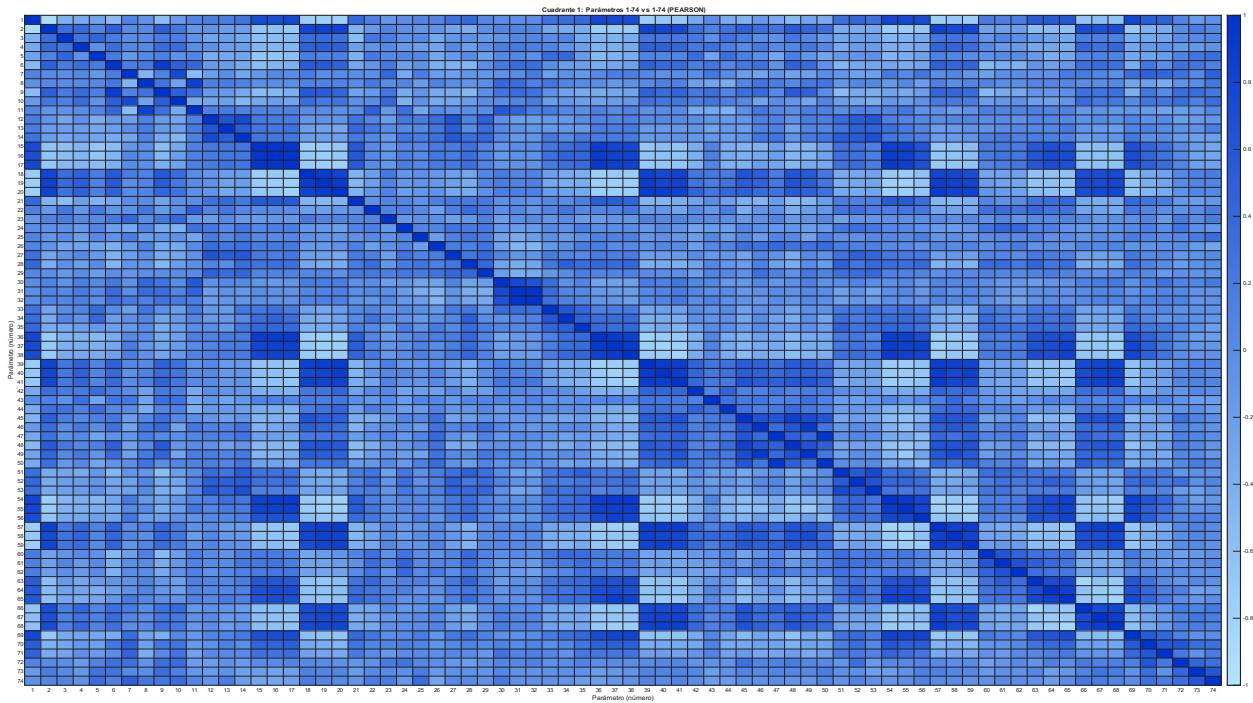


Figura 4.3: Visualización de la correlación de Pearson entre todos los parámetros, primer cuadrante.

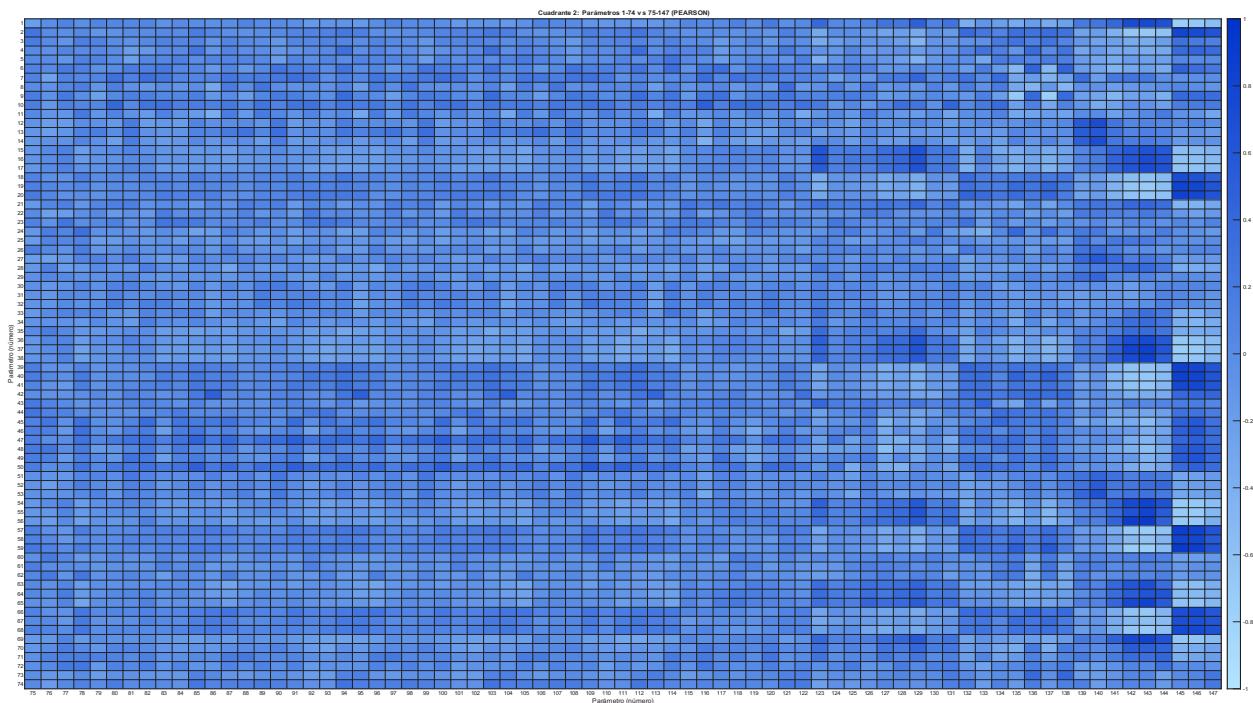


Figura 4.4: Visualización de la correlación de Pearson entre todos los parámetros, segundo cuadrante.



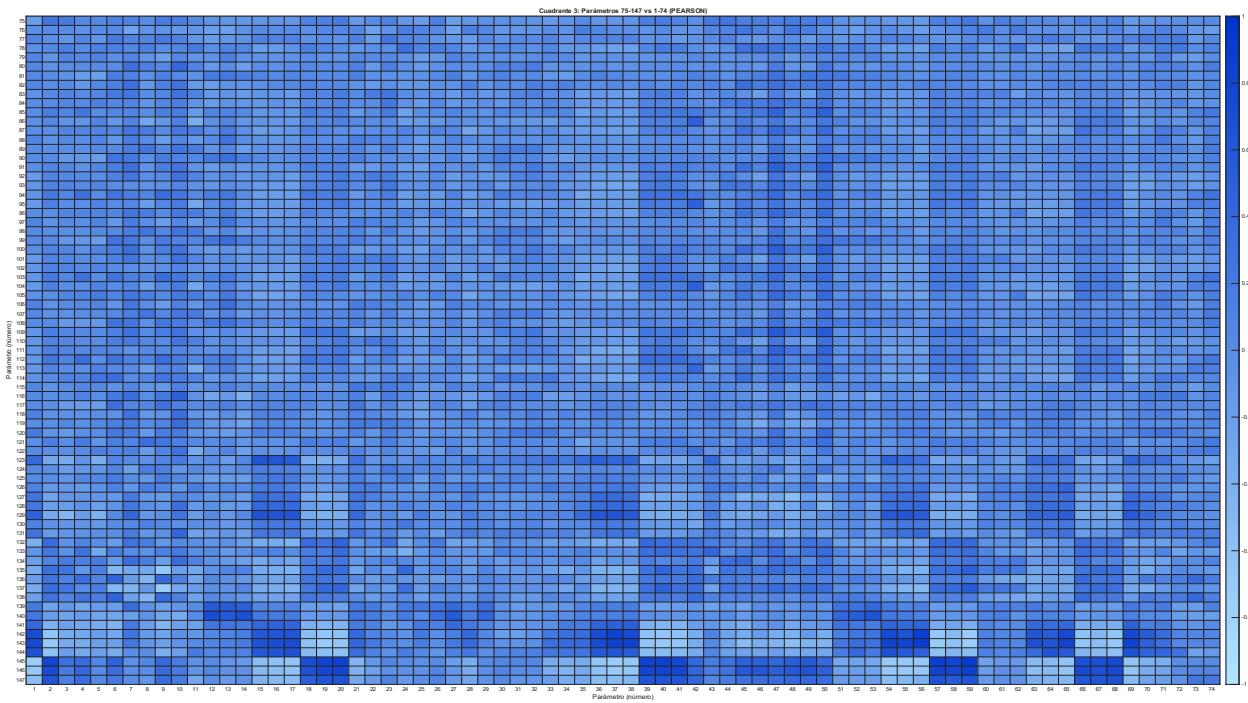


Figura 4.5: Visualización de la correlación de Pearson entre todos los parámetros, tercer cuadrante.

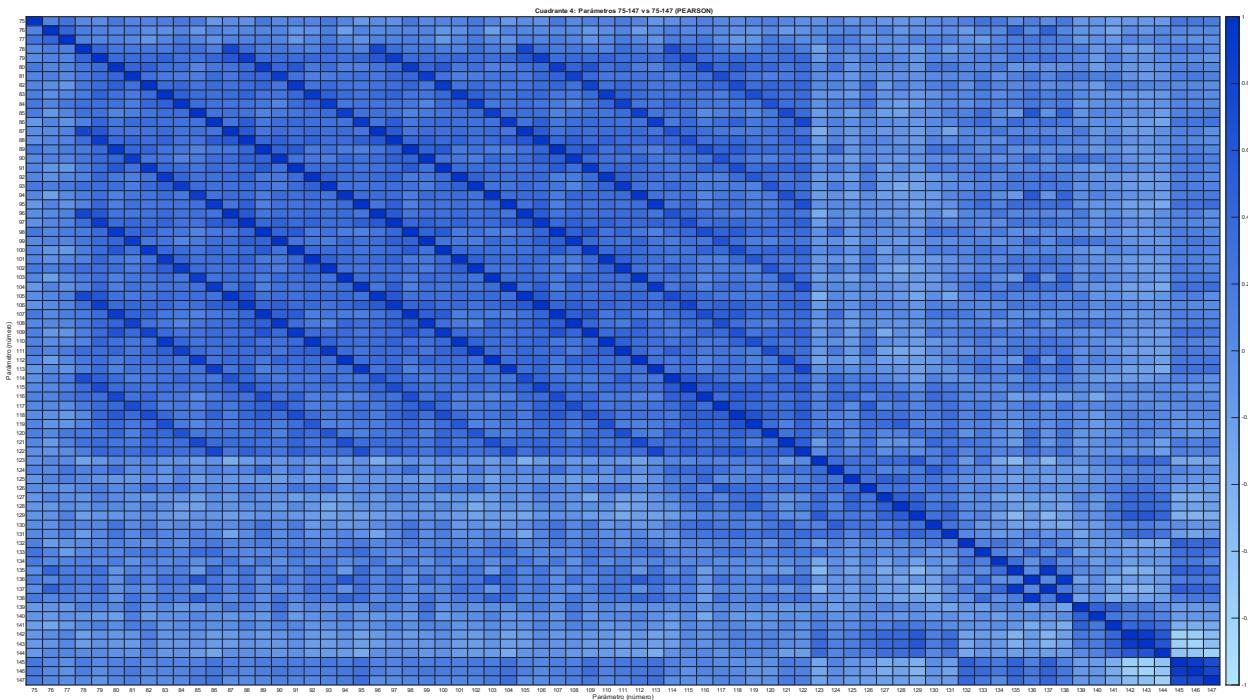


Figura 4.6: Visualización de la correlación de Pearson entre todos los parámetros, cuarto cuadrante.



Tabla 4.5: Número asociado a cada parámetro en el mapa de correlación.

Número	Parámetro	Número	Parámetro
1	Exp1_fijaciones velocity R1	41	Exp3_fijaciones numero R3
2	Exp1_fijaciones numero R1	42	Exp4_ganancia sacadas R1
3	Exp2_ganancia sacadas R1	43	Exp4_ganancia sacadas R2
4	Exp2_ganancia sacadas R2	44	Exp4_ganancia sacadas R3
5	Exp2_ganancia sacadas R3	45	Exp4_sacadas correctivas max distances R1
6	Exp2_sacadas correctivas max distances R1	46	Exp4_sacadas correctivas max distances R2
7	Exp2_sacadas correctivas max distances R2	47	Exp4_sacadas correctivas max distances R3
8	Exp2_sacadas correctivas max distances R3	48	Exp4_sacadas correctivas durations R1
9	Exp2_sacadas correctivas durations R1	49	Exp4_sacadas correctivas durations R2
10	Exp2_sacadas correctivas durations R2	50	Exp4_sacadas correctivas durations R3
11	Exp2_sacadas correctivas durations R3	51	Exp4_coef unificado retraso R1
12	Exp2_coef unificado retraso R1	52	Exp4_coef unificado retraso R2
13	Exp2_coef unificado retraso R2	53	Exp4_coef unificado retraso R3
14	Exp2_coef unificado retraso R3	54	Exp4_fijaciones velocity R1
15	Exp2_fijaciones velocity R1	55	Exp4_fijaciones velocity R2
16	Exp2_fijaciones velocity R2	56	Exp4_fijaciones velocity R3
17	Exp2_fijaciones velocity R3	57	Exp4_fijaciones numero R1
18	Exp2_fijaciones numero R1	58	Exp4_fijaciones numero R2
19	Exp2_fijaciones numero R2	59	Exp4_fijaciones numero R3
20	Exp2_fijaciones numero R3	60	Exp5_ganancia sacadas R1
21	Exp3_ganancia sacadas R1	61	Exp5_ganancia sacadas R2
22	Exp3_ganancia sacadas R2	62	Exp5_ganancia sacadas R3
23	Exp3_ganancia sacadas R3	63	Exp5_fijaciones velocity R1
24	Exp3_coef unificado anticipacion R1	64	Exp5_fijaciones velocity R2
25	Exp3_coef unificado anticipacion R2	65	Exp5_fijaciones velocity R3
26	Exp3_coef unificado anticipacion R3	66	Exp5_fijaciones numero R1
27	Exp3_coef unificado retraso R1	67	Exp5_fijaciones numero R2
28	Exp3_coef unificado retraso R2	68	Exp5_fijaciones numero R3
29	Exp3_coef unificado retraso R3	69	Exp6_smooth pursuit velocidades R1
30	Exp3_antisacadas precision espacial R1	70	Exp6_smooth pursuit velocidades R2
31	Exp3_antisacadas precision espacial R2	71	Exp6_smooth pursuit velocidades R3
32	Exp3_antisacadas precision espacial R3	72	Exp6_smooth pursuit errores seguimiento R1
33	Exp3_antisacadas tiempo predicción R1	73	Exp6_smooth pursuit errores seguimiento R2
34	Exp3_antisacadas tiempo predicción R2	74	Exp6_smooth pursuit errores seguimiento R3
35	Exp3_antisacadas tiempo predicción R3	75	Exp6_smooth pursuit duraciones pursuit R1
36	Exp3_fijaciones velocity R1	76	Exp6_smooth pursuit duraciones pursuit R2
37	Exp3_fijaciones velocity R2	77	Exp6_smooth pursuit duraciones pursuit R3
38	Exp3_fijaciones velocity R3	78	Exp7_convex hull R1
39	Exp3_fijaciones numero R1	79	Exp7_convex hull R2
40	Exp3_fijaciones numero R2	80	Exp7_convex hull R3



Tabla 4.6: Número asociado a cada parámetro en el mapa de correlación.

Número	Parámetro	Número	Parámetro
81	Exp7_convex hull R4	121	Exp7_shannon en R8
82	Exp7_convex hull R5	122	Exp7_shannon en R9
83	Exp7_convex hull R6	123	Exp7_sample en R1
84	Exp7_convex hull R7	124	Exp7_sample en R2
85	Exp7_convex hull R8	125	Exp7_sample en R3
86	Exp7_convex hull R9	126	Exp7_sample en R4
87	Exp7_bcea 68 R1	127	Exp7_sample en R5
88	Exp7_bcea 68 R2	128	Exp7_sample en R6
89	Exp7_bcea 68 R3	129	Exp7_sample en R7
90	Exp7_bcea 68 R4	130	Exp7_sample en R8
91	Exp7_bcea 68 R5	131	Exp7_sample en R9
92	Exp7_bcea 68 R6	132	Exp8_ganancia sacadas R1
93	Exp7_bcea 68 R7	133	Exp8_ganancia sacadas R2
94	Exp7_bcea 68 R8	134	Exp8_ganancia sacadas R3
95	Exp7_bcea 68 R9	135	Exp8_sacadas correctivas max distances R1
96	Exp7_bcea 95 R1	136	Exp8_sacadas correctivas max distances R2
97	Exp7_bcea 95 R2	137	Exp8_sacadas correctivas durations R1
98	Exp7_bcea 95 R3	138	Exp8_sacadas correctivas durations R2
99	Exp7_bcea 95 R4	139	Exp8_coef unificado retraso R1
100	Exp7_bcea 95 R5	140	Exp8_coef unificado retraso R2
101	Exp7_bcea 95 R6	141	Exp8_coef unificado retraso R3
102	Exp7_bcea 95 R7	142	Exp8_fijaciones velocity R1
103	Exp7_bcea 95 R8	143	Exp8_fijaciones velocity R2
104	Exp7_bcea 95 R9	144	Exp8_fijaciones velocity R3
105	Exp7_rms distance R1	145	Exp8_fijaciones numero R1
106	Exp7_rms distance R2	146	Exp8_fijaciones numero R2
107	Exp7_rms distance R3	147	Exp8_fijaciones numero R3
108	Exp7_rms distance R4	—	—
109	Exp7_rms distance R5	—	—
110	Exp7_rms distance R6	—	—
111	Exp7_rms distance R7	—	—
112	Exp7_rms distance R8	—	—
113	Exp7_rms distance R9	—	—
114	Exp7_shannon en R1	—	—
115	Exp7_shannon en R2	—	—
116	Exp7_shannon en R3	—	—
117	Exp7_shannon en R4	—	—
118	Exp7_shannon en R5	—	—
119	Exp7_shannon en R6	—	—
120	Exp7_shannon en R7	—	—



4.1.3 Variabilidad Intra sujeto e Inter sujeto

Para evaluar la robustez y estabilidad de los parámetros oculomotores, se analizó la variabilidad intra sujeto (diferencias entre repeticiones de un mismo sujeto) e inter sujeto (diferencias entre sujetos) en aquellos parámetros que disponen de varias rondas o repeticiones. El análisis se realizó mediante el cálculo del coeficiente de variación (CV), definido como la razón entre la desviación estándar y la media de los valores, tanto para las repeticiones de cada sujeto (intra) como para el conjunto de sujetos en cada ronda (inter).

El procedimiento consistió en identificar los parámetros con múltiples rondas, extraer los valores correspondientes de cada repetición y calcular el CV intra sujeto para cada individuo y el CV inter sujeto para cada ronda. Posteriormente, se calcularon la media y la mediana de estos coeficientes para cada parámetro y experimento.

A continuación, en las figuras 4.7 y 4.8, se muestran dos ejemplos representativos de las figuras generadas en el análisis de variabilidad. Estas ilustran la distribución de los valores y la dispersión intra e inter sujeto para parámetros concretos en distintos experimentos.

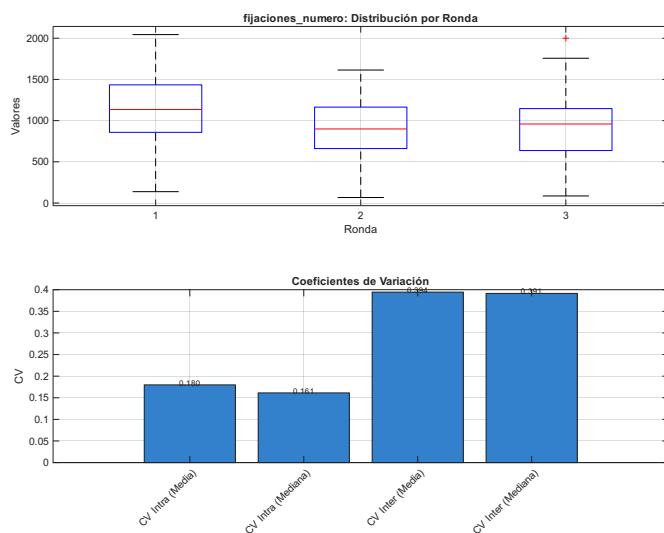


Figura 4.7: Ejemplo de variabilidad intra e inter sujeto para el parámetro *fijaciones_numero* en el Experimento 2.



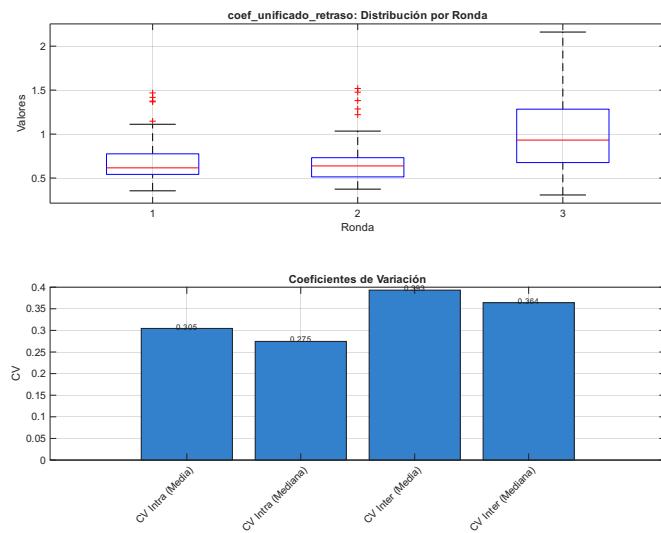


Figura 4.8: Ejemplo de variabilidad intra e inter sujeto para el parámetro *coef_unificado_retraso* en el Experimento 8.

Observaciones destacadas:

A partir de los resultados presentados en la Tabla 4.7, se pueden extraer las siguientes conclusiones principales sobre la confiabilidad de los parámetros evaluados:

- **Experimento 6 (smooth pursuit):** Se observan ratios intra/inter muy elevados (4.00 y 2.75), lo que sugiere problemas de confiabilidad en estos parámetros para este experimento.
- **Fijaciones (velocity y número):** Estos parámetros muestran generalmente ratios bajos (0.20–0.40), lo que indica una buena confiabilidad y estabilidad en las medidas repetidas.
- **Parámetros más confiables:** Aquellos con ratios consistentemente bajos (<0.5), como *fijaciones_velocity*, pueden considerarse los más robustos para la evaluación intra e inter sujeto.

El ratio intra/inter sujeto permite identificar de forma rápida qué parámetros presentan mayor estabilidad y son más adecuados para medidas repetidas en experimentos ocumotores. Un menor valor de coeficiente de variación (CV) indica mayor estabilidad del parámetro, mientras que valores elevados reflejan una mayor dispersión relativa.

En resumen, la Tabla 4.7 sintetiza estos resultados y facilita la comparación de la confiabilidad de los distintos parámetros analizados.



Tabla 4.7: Coeficiente de variación (CV) intra sujeto e inter sujeto para los principales parámetros y experimentos.

Exp	Parámetro	CV Intra (Media)	CV Inter (Media)	Ratio Intra/Inter
2	ganancia_sacadas	0.12	0.15	0.80
2	sacadas_correctivas_max_distances	0.53	0.45	1.18
2	sacadas_correctivas_durations	0.31	0.37	0.84
2	coef_unificado_anticipacion	0.14	0.20	0.70
2	coef_unificado_retraso	0.16	0.36	0.44
2	fijaciones_velocity	0.12	0.52	0.23
2	fijaciones_numero	0.18	0.39	0.46
3	ganancia_sacadas	0.18	0.24	0.75
3	sacadas_correctivas_max_distances	0.51	0.94	0.54
3	sacadas_correctivas_durations	0.30	0.85	0.35
3	coef_unificado_anticipacion	0.17	0.19	0.89
3	coef_unificado_retraso	0.14	0.23	0.61
3	antisacadas_precision_espacial	0.13	0.35	0.37
3	antisacadas_tiempo_prediccion	0.16	0.25	0.64
3	fijaciones_velocity	0.11	0.50	0.22
3	fijaciones_numero	0.17	0.47	0.36
4	ganancia_sacadas	0.10	0.22	0.45
4	sacadas_correctivas_max_distances	0.47	0.66	0.71
4	sacadas_correctivas_durations	0.51	0.69	0.74
4	coef_unificado_anticipacion	0.22	0.22	1.00
4	coef_unificado_retraso	0.12	0.30	0.40
4	fijaciones_velocity	0.13	0.53	0.25
4	fijaciones_numero	0.16	0.46	0.35
5	ganancia_sacadas	0.38	0.70	0.54
5	fijaciones_velocity	0.13	0.43	0.30
5	fijaciones_numero	0.19	0.43	0.44
6	smooth_pursuit_velocidades	0.40	0.10	4.00
6	smooth_pursuit_errores_seguimiento	0.11	0.04	2.75
6	smooth_pursuit_duracioness_pursuit	0.02	~0	—
7	convex_hull	0.48	0.51	0.94
7	bcea_68	0.50	0.53	0.94
7	bcea_95	0.50	0.53	0.94
7	rms_distance	0.24	0.27	0.89
7	shannon_en	0.11	0.14	0.79
7	sample_en	0.36	0.43	0.84
8	ganancia_sacadas	0.21	0.29	0.72
8	sacadas_correctivas_max_distances	0.83	1.07	0.78
8	sacadas_correctivas_durations	0.80	1.11	0.72
8	coef_unificado_anticipacion	0.18	0.20	0.90
8	coef_unificado_retraso	0.30	0.39	0.77
8	fijaciones_velocity	0.20	0.56	0.36
8	fijaciones_numero	0.25	0.44	0.57



4.1.4 Modelos de regresión para la predicción de la edad

El objetivo principal de este trabajo ha sido predecir la edad de los participantes a partir de parámetros extraídos de registros de movimientos oculares, empleando el entorno *Regression Learner* de *MATLAB*. Para ello, se han utilizado múltiples modelos de regresión, reservando el 10 % de los datos para test y empleando validación cruzada con $k = 5$. Debido a la naturaleza de los datos, algunos modelos no han podido entrenarse correctamente, ya que ciertos parámetros no se han obtenido en todos los participantes, lo que ha reducido el tamaño efectivo de la muestra para algunos algoritmos.

En la Tabla 4.8 se resumen las métricas principales de los modelos que han podido ser entrenados y evaluados. Se presentan el error cuadrático medio (*RMSE*) y el coeficiente de determinación (R^2) tanto en validación como en test, así como el error absoluto medio (*MAE*). Además, en la Figura 4.9 y Figura 4.10 se muestran comparativamente los valores de *RMSE* y R^2 para todos los modelos evaluados. Por último, se incluyen gráficos de dispersión de valores predichos frente a valores reales para cada modelo (ver Figuras 4.13 a 4.12), que permiten visualizar la capacidad predictiva de cada aproximación.

Tabla 4.8: Resultados de los modelos de regresión entrenados.

Modelo	RMSE (Val)	R^2 (Val)	MAE (Test)	RMSE (Test)	R^2 (Test)
<i>Coarse Tree</i> (2.7)	13.58	≈ 0	8.78	9.80	-0.29
<i>Boosted Trees</i> (2.16)	13.62	-0.01	11.65	13.23	-1.34
<i>Bagged Trees</i> (2.17)	13.50	0.01	12.52	13.97	-1.61
<i>Medium Tree</i> (2.6)	15.36	-0.28	13.04	16.58	-2.68
<i>Fine Tree</i> (2.5)	17.60	-0.68	17.27	23.65	-6.49
<i>Stepwise Linear Regresion</i> (2.4)	66.06	-23.13	27.43	35.08	-15.29
<i>Linear Regresion</i> (2.1)	33	-28.45	NaN	NaN	NaN
<i>Interactions Linear</i> (2.2)	33	-28.45	NaN	NaN	NaN



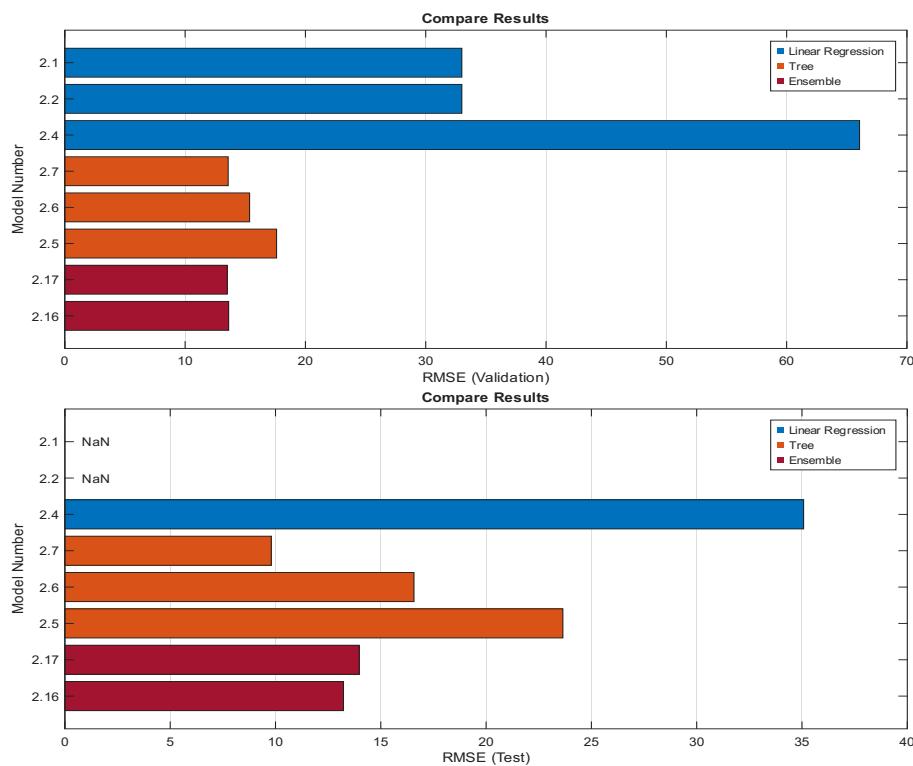


Figura 4.9: Comparativa de $RMSE$ en validación y test para los diferentes modelos.



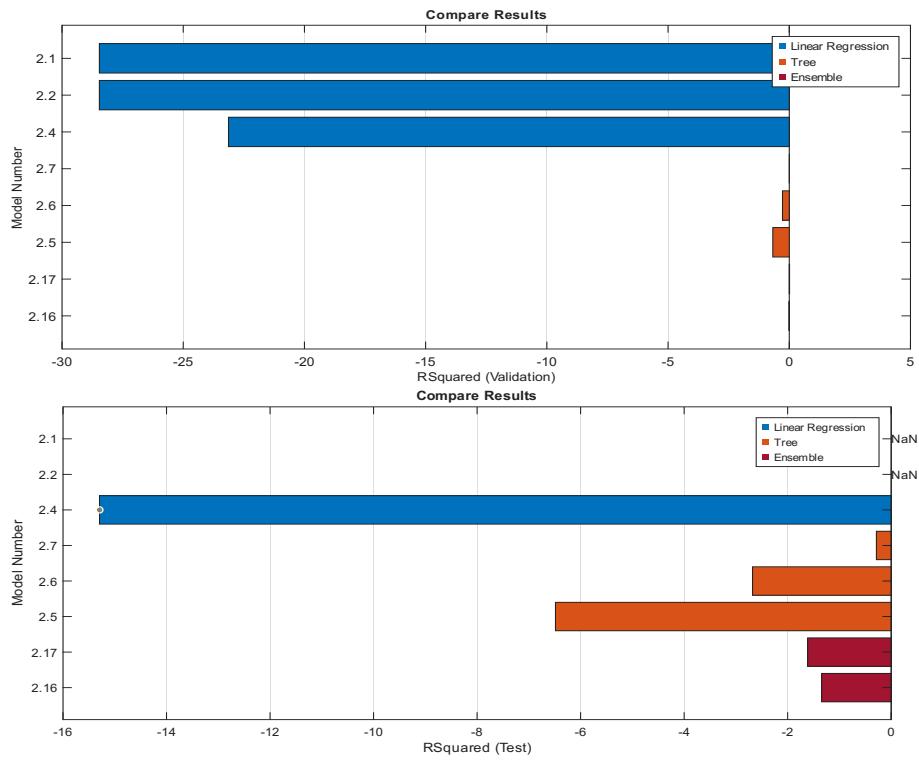


Figura 4.10: Comparativa de R^2 en validación y test para los diferentes modelos.

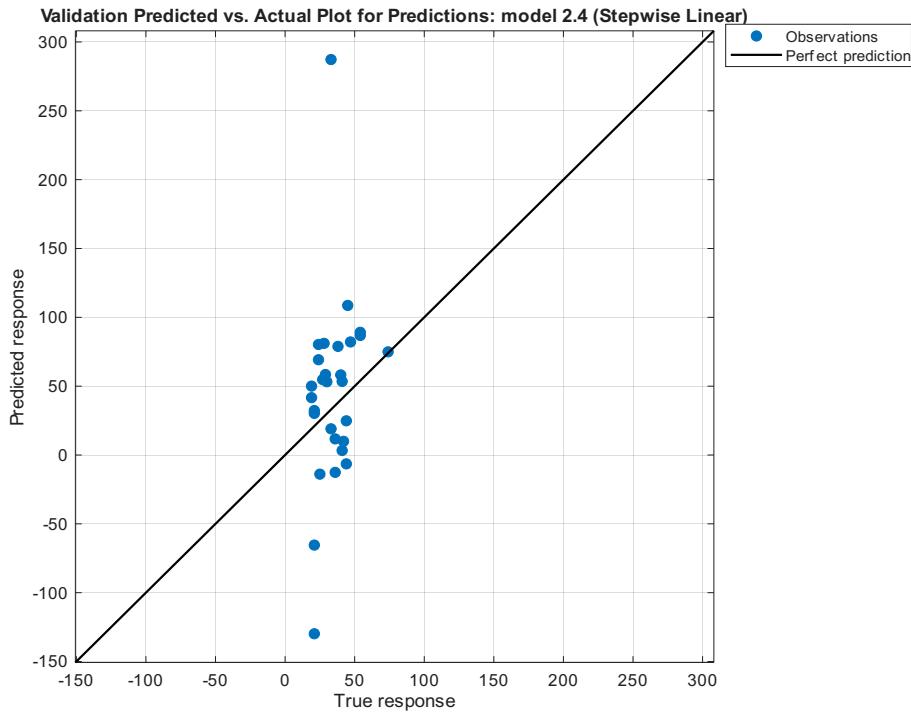


Figura 4.11: Gráficos de valores predichos frente a reales para los modelos seleccionados del modelo *Stepwise Linear Regresion*.



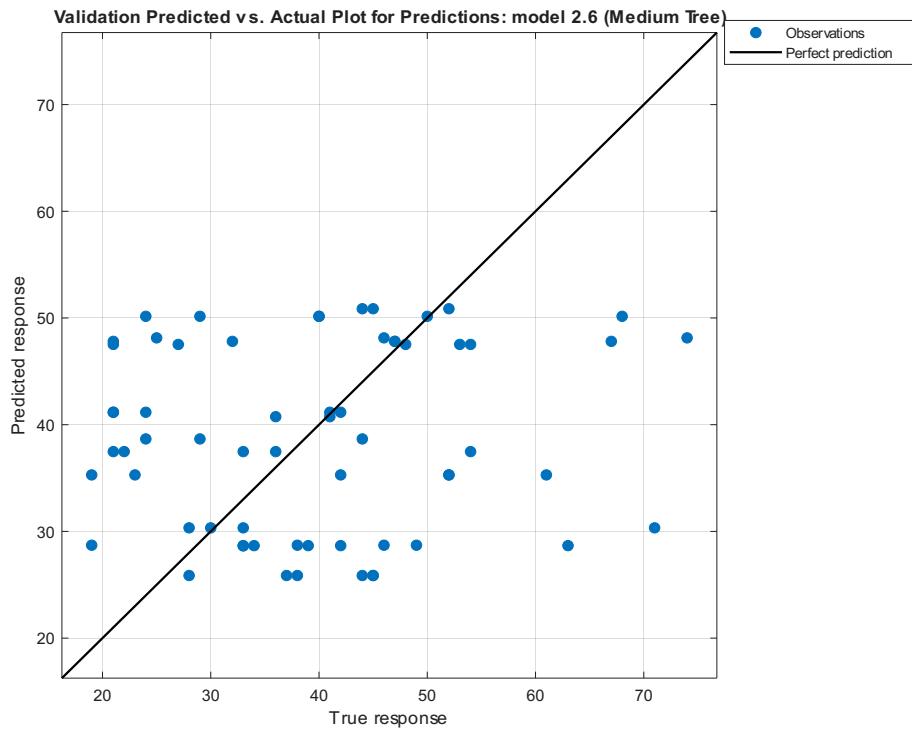


Figura 4.12: Gráficos de valores predichos frente a reales para los modelos seleccionados del modelo *Medium Tree*.

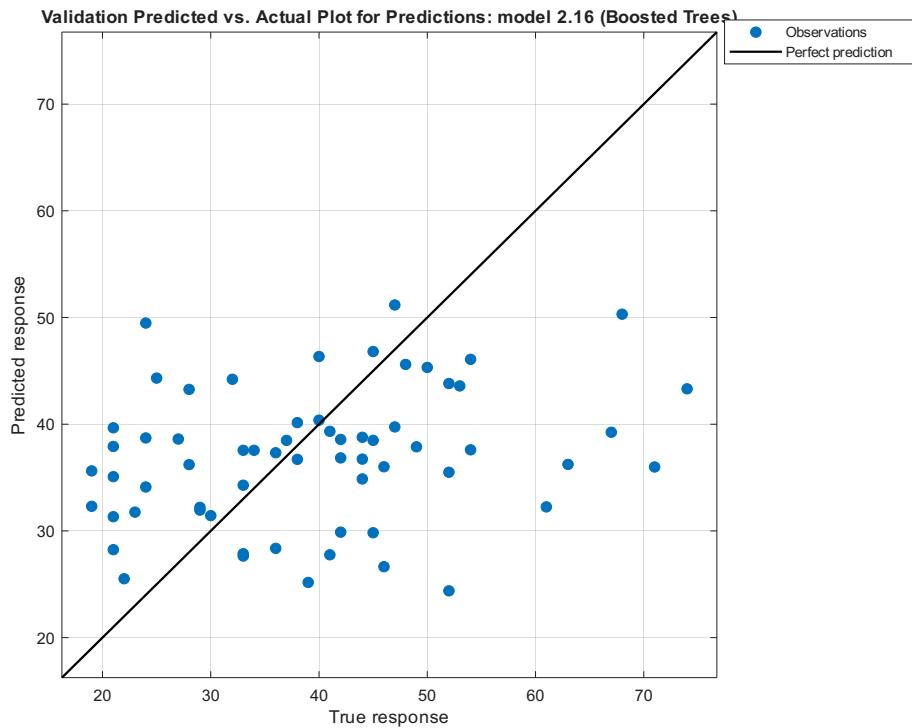


Figura 4.13: Gráficos de valores predichos frente a reales para los modelos seleccionados del modelo *Boosted Tree*.



4.1.5 Análisis de agrupamiento mediante *t-SNE*

Con el objetivo de explorar si los parámetros extraídos permiten distinguir entre grupos de edad, se ha realizado un análisis de agrupamiento utilizando la técnica *t-distributed Stochastic Neighbor Embedding* (*t-SNE*). Para este análisis, se seleccionaron las diez variables con mayor correlación absoluta con la edad, entre las que se incluyen *fijaciones_velocity*, *coef_unificado_anticipacion*, *fijaciones_numero*, *sacadas_correctivas_durations*, *sample_en*, *sacadas_correctivas_max_distances*, *smooth_pursuit_velocidades*, *antisacadas_precision_espacial*, *ganancia_sacadas* y *shannon_en*. El número de casos disponibles para cada variable varía considerablemente, por lo que la matriz final utilizada para el análisis incluyó únicamente los 204 casos con datos completos en todas las variables seleccionadas.

Los participantes se dividieron en dos grupos de edad según la mediana (40 años): jóvenes (≤ 40 años, 106 casos) y mayores (>40 años, 98 casos). El algoritmo *t-SNE* se ejecutó con una *perplexity* de 30, tras estandarizar las variables y eliminar valores no válidos (*Nan/Inf*).

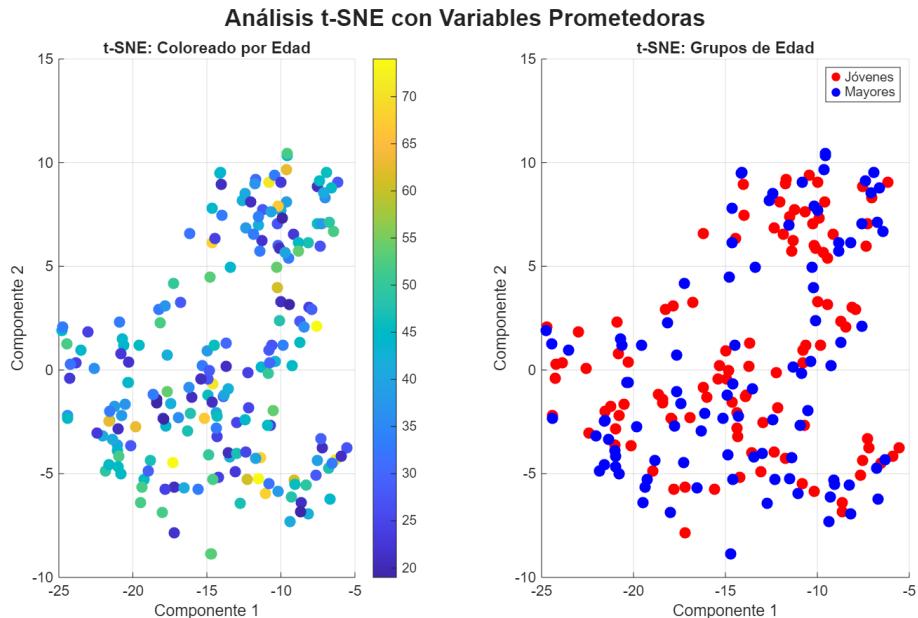


Figura 4.14: Análisis de agrupamiento mediante *t-SNE*. Cada punto representa un participante, coloreado según el grupo de edad (jóvenes y mayores).

La Figura 4.14 muestra el resultado del análisis de agrupamiento mediante *t-SNE*. En el espacio bidimensional generado, ambos grupos de edad aparecen muy dispersos y no se observa una separación clara entre jóvenes y mayores. Este resultado sugiere que, incluso combinando las variables más prometedoras, no se logra una agrupación natural de los participantes en función de la edad a partir de los parámetros extraídos. La dispersión



observada refuerza la conclusión de que los parámetros disponibles no contienen suficiente información discriminativa para la edad.

4.2 Discusión de los resultados

A lo largo de este trabajo se ha conseguido desarrollar un flujo de procesado completo que parte de los datos en crudo de los participantes y permite alcanzar los diferentes objetivos planteados. El preprocesado implementado ha resultado exitoso, incluyendo una calibración temporal y espacial precisa, así como un filtrado eficaz de artefactos y parpadeos. Además, se ha realizado la separación de las señales para facilitar su uso en los análisis posteriores. Cabe destacar especialmente la importancia de la calibración temporal, ya que ha permitido alinear correctamente los registros de todos los participantes y asegurar la comparabilidad entre experimentos (3.4).

En una segunda etapa, se han extraído métricas relevantes a partir de la detección de fijaciones y sacadas, calculadas mediante la velocidad euclídea entre muestras consecutivas. A partir de estos eventos oculomotores se han obtenido numerosos parámetros descriptores, aunque también se han calculado otros parámetros independientes de las fijaciones y sacadas. Posteriormente, se ha explorado la correlación de estos parámetros con la edad de los participantes, obteniendo resultados poco satisfactorios, como se observa en la sección de correlaciones (4.1.1). La mayoría de los parámetros presentan correlaciones bajas con la edad, y muchos de ellos dependen en gran medida de la segmentación en fijaciones y sacadas, lo que puede limitar su utilidad.

Un aspecto relevante es que la calibración temporal, aunque necesaria para la alineación de los datos, podría haber afectado a los parámetros temporales extraídos. Si el retardo inicial de cada participante se mantiene constante a lo largo de todos los experimentos, la corrección aplicada podría haber eliminado información relevante sobre diferencias individuales en el tiempo de reacción o anticipación. Esto podría explicar en parte la baja correlación observada entre los parámetros temporales y la edad, a pesar de que la literatura reporta ejemplos de éxito en este tipo de análisis (3.4), (4.1.1).

Por otro lado, se ha comprobado que varios parámetros presentan una buena estabilidad intra sujeto e inter sujeto, como se muestra en el análisis de variabilidad (4.1.3). Sin embargo, esta estabilidad no se ha traducido en una mayor capacidad predictiva respecto a la edad. Además, el análisis de la matriz de correlación entre parámetros (4.1.2) ha puesto de manifiesto la existencia de redundancias importantes, especialmente entre métricas derivadas de la dispersión espacial y entre el número y la velocidad de fijaciones. Esto sugiere que una reducción de la dimensionalidad o una selección más cuidadosa de los parámetros podría ser necesaria en futuros trabajos.



En cuanto a la predicción de la edad mediante modelos de regresión, los resultados han sido claramente insatisfactorios. Como se observa en las tablas y figuras de resultados (4.1.4), las métricas obtenidas son muy bajas, con valores negativos de R^2 en test, lo que indica que los modelos no son capaces de explicar la variabilidad de la edad a partir de los parámetros extraídos. El error cuadrático medio y el error absoluto medio también resultan elevados en comparación con el rango de edades de la muestra.

El análisis de agrupamiento mediante t-SNE (4.1.5) refuerza estas conclusiones, ya que no se observa una separación clara entre los grupos de edad definidos (menores y mayores de 40 años). Los puntos correspondientes a ambos grupos aparecen mezclados en el espacio bidimensional, lo que indica que ni siquiera combinando los parámetros más prometedores se logra una agrupación natural de los participantes en función de la edad.

Por último, cabe señalar que la variabilidad inter sujeto observada en parámetros como el número y la velocidad de fijaciones es considerablemente alta (4.1.3). Esto sugiere que existe una gran heterogeneidad en el comportamiento oculomotor entre individuos, incluso bajo las mismas condiciones experimentales. Esta variabilidad puede dificultar la obtención de parámetros robustos y generalizables, y refuerza la idea de que el desarrollo de algoritmos universales para la extracción de métricas oculomotoras es un reto complejo.

En resumen, aunque se ha logrado establecer un pipeline sólido de procesado y extracción de parámetros, los resultados obtenidos muestran las dificultades inherentes a la predicción de la edad a partir de movimientos oculares. Las limitaciones identificadas en la correlación y la capacidad predictiva de los parámetros sugieren la necesidad de explorar nuevas aproximaciones y de considerar la alta variabilidad interindividual en futuros estudios.



CAPÍTULO 5

CONCLUSIONES Y LINEAS FUTURO

En este trabajo se ha desarrollado un flujo de procesado completo para el análisis de movimientos oculares, desde los datos en crudo hasta la extracción de parámetros y la aplicación de modelos de predicción. El preprocesado, incluyendo la calibración temporal y espacial, así como el filtrado de artefactos y la segmentación de señales, ha demostrado ser robusto y funcional. Sin embargo, los resultados obtenidos muestran que los parámetros extraídos presentan una baja correlación con la edad y que los modelos de regresión no han logrado predecir la edad de los participantes con precisión aceptable. Además, la alta variabilidad intersujeto y la redundancia entre algunos parámetros limitan la capacidad predictiva y la generalización de los modelos.

De cara a líneas futuras, es fundamental ampliar el tamaño y la diversidad de la muestra de participantes, especialmente en los extremos del rango de edad, para mejorar la potencia estadística y la representatividad de los resultados. También sería recomendable explorar nuevos parámetros menos dependientes del tiempo y de la segmentación en fijaciones y sacadas, así como revisar en profundidad el proceso de calibración temporal para asegurar que no elimina información relevante de los parámetros temporales.

Otra línea interesante sería aplicar este flujo de procesado a otros problemas, como la identificación de sujetos, la predicción de patologías o el análisis de diferencias individuales en tareas cognitivas, siempre que se disponga de información adicional sobre los participantes. Además, podría ser útil investigar técnicas de reducción de dimensionalidad y selección de variables para minimizar la redundancia y mejorar la interpretabilidad de los modelos.

Por último, sería conveniente comparar el pipeline desarrollado con otros enfoques y algoritmos de la literatura, así como evaluar su aplicabilidad en contextos clínicos o en estudios longitudinales para analizar la evolución de los patrones oculomotores a lo largo del tiempo. Todo ello contribuiría a avanzar en la búsqueda de biomarcadores oculares robustos.

BIBLIOGRAFÍA

- [1] Todd J. Anderson and Michael R. MacAskill: *Eye movements in patients with neurodegenerative disorders.* Nature Reviews Neurology, 9(2):74–85, 2013.
- [2] Charalampia A. et al. Antoniades: *A new tool to assess eye movements in patients with neurodegenerative disorders.* Annals of Clinical and Translational Neurology, 1(1):11–19, 2013.
- [3] G. et al. Bargary: *Individual differences in human eye movements: an oculomotor signature?* Vision Research, 141:157–169, 2017.
- [4] Graham R. Barnes: *Cognitive processes involved in smooth pursuit eye movements.* Brain and Cognition, 68(3):309–326, 2008.
- [5] Peter J. Benson, Stephanie A. Beedie, Everett Shephard, Ina Giegling, Dan Rujescu, and David St Clair: *Simple viewing tests can detect eye movement abnormalities that distinguish schizophrenia cases from controls with exceptional accuracy.* Biological Psychiatry, 72(9):716–724, 2012.
- [6] Ali Borji: *Saliency prediction in the deep learning era: Successes and limitations.* arXiv preprint arXiv:1901.09024, 2019.
- [7] Romuald Carette, Mahmoud Elbattah, Gilles Dequen, Jean Luc Guérin, and Federica Cilia: *Learning to predict autism spectrum disorder based on the visual patterns of eye-tracking scanpaths.* HEALTHINF 2019 - 12th International Conference on Health Informatics, pages 103–112, 2019.
- [8] James H. Cole and Katja Franke: *Predicting age using neuroimaging: Innovative brain ageing biomarkers.* Trends in Neurosciences, 40(12):681–690, 2017.
- [9] Trevor J. Crawford, Steve Higham, Thomas Renvoize, Jillian Patel, Martin Dale, Alia Suriya, and Sarah Tetley: *Inhibitory control of saccadic eye movements and cognitive impairment in alzheimer’s disease.* Biological Psychiatry, 74(2):113–119, 2013.
- [10] Stefan Dowiasch, Sascha Marx, Wolfgang Einhäuser, and Frank Bremmer: *Effects of aging on eye movements in the real world.* Frontiers in Human Neuroscience, 9:46, 2015.

- [11] A. T. Duchowski: *Eye Tracking Methodology: Theory and Practice*. Springer, 3rd ed. edition, 2017.
- [12] Miguel P. Eckstein, Belen Guerra-Carrillo, Andrew T. Singley, and Silvia A. Bunge: *Beyond eye gaze: What else can eyetracking reveal about cognition and cognitive development?* Developmental Cognitive Neuroscience, 25:69–91, 2017.
- [13] Ralf Engbert and Reinhold Kliegl: *Microsaccades uncover the orientation of covert attention*. Vision Research, 43(9):1035–1045, 2003.
- [14] Terje Falck-Ytter, Sven Bölte, and Gustaf Gredebäck: *Eye tracking in early autism research*. Journal of Neurodevelopmental Disorders, 5(1):28, 2013.
- [15] Kunihiko Fukushima and Junko Fukushima: *Disorders of voluntary saccades in patients with frontal lobe damage: their relation to lesion location*. Cortex, 49(1):1–21, 2013.
- [16] Sergio García-Blanco, Julie Daucourt, Naima Deggouj, and Monique Lipski: *Safide: Detection of saccade and fixation periods based on eye-movement attributes from video-oculography, scleral coil or electrooculography data*. Computer Methods and Programs in Biomedicine, 231:107403, 2023.
- [17] Alessandro Grillini, Dieter Ombelet, Roshni Shetty Soans, and Frans W. Cornelissen: *Evidence for five types of fixation during a random saccade eye tracking task: Implications for the study of oculomotor fatigue*. arXiv preprint arXiv:2406.01496, 2024.
- [18] Roy S. Hessels, Diederick C. Niehorster, Chantal Kemner, and Ignace T. C. Hooge: *Noise-robust fixation detection in eye movement data: Identification by two-means clustering (i2mc)*. Behavior Research Methods, 49(5):1802–1823, 2017.
- [19] Steve Horvath: *Dna methylation age of human tissues and cell types*. Genome Biology, 14(10):R115, 2013.
- [20] Sam B. Hutton: *Cognitive control of saccadic eye movements*. Brain and Cognition, 68:327–340, 2019.
- [21] Elizabeth L. Irving, Murray J. Steinbach, Linda Lillakas, Ramesh J. Babu, and Nadine Hutchings: *Horizontal saccade dynamics across the human life span*. Investigative Ophthalmology & Visual Science, 47(6):2478–2484, 2006.
- [22] Michael I. Jordan and Tom M. Mitchell: *Machine learning: Trends, perspectives, and prospects*. Science, 349(6245):255–260, 2015.
- [23] Paweł Kasprzowski and Katarzyna Harezlak: *The use of eye tracking in the diagnosis of mental disorders: A review of current advancements and research challenges*. Cognitive Systems Research, 51:31–37, 2018.



- [24] Hyun Lee, Min Lee, and Sang Hun Lee: *Predicting cognitive decline with eye movement features*. Scientific Reports, 9(1):1–10, 2019.
- [25] R. John Leigh and David S. Zee: *The Neurology of Eye Movements*. Oxford University Press, 5th edition, 2015.
- [26] Bo Liu, Qi Chao Zhao, Yuan Yuan Ren, Qing Ju Wang, and Xue Lian Zheng: *An elaborate algorithm for automatic processing of eye movement data and identifying fixations in eye-tracking experiments*. Cognitive Systems Research, 52:555–563, 2018.
- [27] Michael R. MacAskill and Todd J. Anderson: *Eye movements in neurodegenerative diseases*. Current Opinion in Neurology, 25(1):45–53, 2012.
- [28] Susana Martinez-Conde, Jorge Otero-Millan, and Stephen L. Macknik: *The impact of microsaccades on vision: towards a unified theory of saccadic function*. Nature Reviews Neuroscience, 14:83–96, 2013.
- [29] Sebastiaan Mathôt, Edwin S. Dalmaijer, Jonathan Grainger, and Stefan Van der Stigchel: *Automated analysis pipeline for extracting saccade, pupil, and blink parameters using video-based eye tracking*. Vision, 8(1):14, 2024.
- [30] Robert J. Molitor, Philip C. Ko, and Brandon A. Ally: *Eye movements in alzheimer's disease*. Journal of Alzheimer's Disease, 44(1):1–12, 2015.
- [31] Douglas P. Munoz and Stefan Everling: *Look away: The anti-saccade task and the voluntary control of eye movement*. Nature Reviews Neuroscience, 5:218–228, 2004.
- [32] Marcus Oliva, Diederick C. Niehorster, Halszka Jarodzka, and Kenneth Holmqvist: *An adaptive algorithm for fast and reliable online saccade detection*. Behavior Research Methods, 51(5):2037–2054, 2019.
- [33] Nabil Ouerhani, Tobias Jost, René Müri, Katharina Hüfner, and Stephen Perrig: *Optimizing fixation filters for eye-tracking on small screens*. Frontiers in Neuroscience, 15:616621, 2021.
- [34] Pedro M. Paz-Alonso and Simona Ghetti: *Spatial distribution of fixations during visual search: A shannon entropy approach*. Neuropsychologia, 117:341–349, 2018. <https://www.sciencedirect.com/science/article/abs/pii/S0149763418303075>.
- [35] Anne Peltsch, Amanda Hemraj, Alexander Garcia, and Douglas P. Munoz: *Age-related trends in saccade characteristics among the elderly*. Neurobiology of Aging, 32(4):669–679, 2011.
- [36] Keith Rayner, Monica S. Castelhano, and Jinmian Yang: *Eye movements and the perceptual span in silent reading*. Visual Cognition, 20(4-5):383–402, 2012.
- [37] Joanna Raynowska and Jacob L. Orquin: *Eye-tracking for dummies: A guide for the*



- uninitiated.* Behavior Research Methods, 50(5):2210–2227, 2018.
- [38] Héctor Relaño-Iborra, Johannes Zaar, and Torsten Dau: *Pupils pipeline: A flexible matlab toolbox for eyetracking and pupillometry data processing.* arXiv preprint arXiv:2011.05118, 2020.
- [39] Joshua S. Richman and J. Randall Moorman: *Physiological time-series analysis using approximate entropy and sample entropy.* American Journal of Physiology - Heart and Circulatory Physiology, 278(6):H2039–H2049, 2000. <https://pmc.ncbi.nlm.nih.gov/articles/PMC10760742/>.
- [40] Jérôme Tagu, Karine Doré-Mazars, Christophe Lemoine-Lardennois, and Dorine Vergilino-Perez: *Fixation-related saccadic inhibition in free viewing in response to stimulus saliency.* Scientific Reports, 8(1):15429, 2018.
- [41] Yoshikazu Terao, Hiroshi Fukuda, and Okihide Hikosaka: *What do eye movements tell us about patients with neurological disorders? — an introduction to saccadic eye movements.* Psychiatry and Clinical Neurosciences, 71(2):79–91, 2017.
- [42] Deniz Toker, Chris Bissell, Paolo Ciancarini, and Gerald R. Hayes: *Visualizing eye tracking convex hull areas: A pilot study for understanding how craft workers interpret 2d construction drawings.* Proceedings of the 2017 ACM Conference on Computer Supported Cooperative Work and Social Computing, pages 1039–1051, 2017. https://www.researchgate.net/publication/319459132_Visualizing_Eye_Tracking_Convex_Hull_Areas_A_Pilot_Study_for_Understanding_How_Craft_Workers_Interpret_2D_Construction_Drawings.
- [43] Pei Yung Tseng, Ian G. M. Cameron, Gord Pari, John N. Reynolds, Douglas P. Munoz, and Laurent Itti: *High-throughput classification of clinical populations from natural viewing eye movements.* Journal of Neurology, 260(1):275–284, 2013.
- [44] Chunhua Wang, Lei Zhang, Yu Li, et al.: *Eye movement analysis in neurological disorders using bivariate contour ellipse area.* Frontiers in Neurology, 13:9112722, 2022. <https://pmc.ncbi.nlm.nih.gov/articles/PMC9112722/>.
- [45] Yang Xu, Chen Li, and Ying Zhang: *Eye movement biomarkers for neurological disorders: Rms-distance analysis.* Frontiers in Neuroscience, 14:588, 2020. <https://pmc.ncbi.nlm.nih.gov/articles/PMC7725698/>.
- [46] Raimondas Zemblys, Diederick C. Niehorster, Oleg Komogortsev, and Kenneth Holmqvist: *Using machine learning to detect events in eye-tracking data.* Behavior Research Methods, 50(1):160–181, 2018.

