



UNIVERSIDAD TÉCNICA DE AMBATO

**FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E
INDUSTRIAL
CARRERA DE TELECOMUNICACIONES**

Tema:

**PROTOTIPO ELECTRÓNICO DE MONITOREO CEREBRAL EN TIEMPO
REAL CON ENFOQUE EN LA DETECCIÓN TEMPRANA DE
ENFERMEDADES NEURODEGENERATIVAS MEDIANTE TÉCNICAS DE
INTELIGENCIA ARTIFICIAL**

Trabajo de titulación modalidad Proyecto de Investigación, presentado previo a la
obtención del título de Ingeniero en Telecomunicaciones

ÁREA: Electrónica

LÍNEA DE INVESTIGACIÓN: Electrónica, telecomunicaciones y sistema de control

AUTORES: Kevin Renato Gamboa Cornejo

Kevin Isrrael Zamora Lozada

TUTOR: Ing. Edgar Patricio Córdova Córdova Mg

Ambato - Ecuador

julio 2026

APROBACIÓN DEL TUTOR

En calidad de tutor del trabajo de titulación con el tema: PROTOTIPO ELECTRÓNICO DE MONITOREO CEREBRAL EN TIEMPO REAL CON ENFOQUE EN LA DETECCIÓN TEMPRANA DE ENFERMEDADES NEURODEGENERATIVAS MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL, desarrollado bajo la modalidad Proyecto de Investigación por los señores Kevin Renato Gamboa Cornejo y Kevin Israel Zamora Lozada, estudiantes de la Carrera de Telecomunicaciones, de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, de la Universidad Técnica de Ambato, me permito indicar que los estudiantes han sido tutorados durante todo el desarrollo del trabajo hasta su conclusión, de acuerdo a lo dispuesto en el Artículo 17 del Reglamento para la Titulación de Grado en la Universidad Técnica de Ambato y el numeral 6.3 del instructivo del reglamento referido.

Ambato, julio 2026.

Ing. Edgar Patricio Córdova Córdova, MSc.

TUTOR

AUTORÍA

El presente trabajo de titulación con el tema: PROTOTIPO ELECTRÓNICO DE MONITOREO CEREBRAL EN TIEMPO REAL CON ENFOQUE EN LA DETECCIÓN TEMPRANA DE ENFERMEDADES NEURODEGENERATIVAS MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL es absolutamente original, auténtico y personal y ha observado los preceptos establecidos en la Disposición General Quinta del Reglamento para la Titulación de Grado en la Universidad Técnica de Ambato. En tal virtud, el contenido, efectos legales y académicos que se desprenden del mismo son de exclusiva responsabilidad del autor.

Ambato, julio 2026.



Kevin Renato Gamboa Cornejo

C.C. 1805094503

AUTOR



Kevin Israel Zamora Lozada

C.C. 1805171848

AUTOR

DERECHOS DE AUTORES

Autorizamos a la Universidad Técnica de Ambato para que reproduzca total o parcialmente este trabajo de titulación dentro de las regulaciones legales e institucionales correspondientes. Además, cedemos todos los derechos de autor a favor de la institución con el propósito de su difusión pública, por lo tanto, autorizamos su publicación en el repositorio virtual institucional como un documento disponible para la lectura y uso con fines académicos e investigativos de acuerdo con la disposición General Cuarta del Reglamento para la Titulación de Grado en la Universidad Técnica de Ambato.

Ambato, julio 2026.



Kevin Renato Gamboa Cornejo

C.C. 1805094503

AUTOR



Kevin Israel Zamora Lozada

C.C. 1805171848

AUTOR

APROBACIÓN DEL TRIBUNAL DE GRADO

En calidad de par calificador del informe final del trabajo de titulación presentado por los señores Kevin Renato Gamboa Cornejo y Kevin Isrrael Zamora Lozada, estudiantes de la Carrera de Telecomunicaciones, de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, bajo la Modalidad Proyecto de Investigación, titulado **PROTOTIPO ELECTRÓNICO DE MONITOREO CEREBRAL EN TIEMPO REAL CON ENFOQUE EN LA DETECCIÓN TEMPRANA DE ENFERMEDADES NEURODEGENERATIVAS MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL**, nos permitimos informar que el trabajo ha sido revisado y calificado de acuerdo al Artículo 19 del Reglamento para la Titulación de Grado en la Universidad Técnica de Ambato y el numeral 6.4 del instructivo del reglamento referido. Para cuya constancia suscribimos, conjuntamente con el señor presidente del Tribunal.

Ambato, julio 2026.



Ing. Franklin Oswaldo Mayorga Mayorga, Mg.

PRESIDENTE DEL TRIBUNAL



Dr. Freddy Geovanny Benalcazar Palacios

PROFESOR CALIFICADOR

Ing. Fabian Rodrigo Salazar Escobar PhD.

PROFESOR CALIFICADOR

DEDICATORIA

A Dios, por ser el faro que siempre ilumina mi camino. Por haberme brindado la sabiduría, la paciencia y la fortaleza inquebrantable para no desfallecer ante las adversidades y permitirme culminar esta importante etapa de mi vida.

A mis padres, mi mayor ejemplo de lucha, amor y perseverancia. Gracias por sus incontables sacrificios, por sus consejos y por creer en mí incluso en los momentos de duda. Ustedes sembraron en mí la convicción de que el trabajo duro rinde frutos; este triunfo es tan suyo como mío.

A mi abuelito Jaime, por su amor incondicional, su ternura y por ser una figura entrañable que atesoro profundamente. Sus enseñanzas, sus palabras sabias y su cariño han dejado una huella imborrable en mi corazón, inspirándome siempre a ser una mejor persona.

A mi tía Patty, por su cariño constante, sus cuidados y por estar siempre presente con un abrazo y una palabra de aliento cuando más lo necesitaba. Gracias por ser parte fundamental de mi vida y por celebrar conmigo cada pequeño avance.

A mi familia, por ser mi pilar fundamental y mi refugio seguro. Gracias por su comprensión durante mis ausencias, por sus palabras de aliento y por sostenerme incondicionalmente en cada desafío superado.

Y con el alma entera, dedico este logro a mi amado hijo, Matthew. Eres el latido que me impulsa, mi inspiración más pura y mi verdadera razón de ser. Cada noche de desvelo, cada esfuerzo y cada meta alcanzada en este camino llevan tu nombre. Llegar hasta aquí ha sido por y para ti, para demostrarte que con fe, amor y dedicación no existen los imposibles. Eres mi motor de vida, te amo infinitamente.

Kevin R. Gamboa Cornejo

AGRADECIMIENTO

En primer lugar, expreso mi más profunda gratitud a Dios por bendecirme con la salud y las oportunidades necesarias para completar mi formación como Ingeniero en Telecomunicaciones.

A mis padres y a mi familia entera, porque su respaldo fue el cimiento sobre el cual pude construir este proyecto. Sin su apoyo moral y constante ánimo, este sueño no se habría materializado.

A mi alma mater, la Universidad Técnica de Ambato, y en especial a los docentes de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, por la excelencia académica, la guía y los invaluable conocimientos compartidos a lo largo de todos estos años.

A mi tutor de tesis, el Ing. Patricio Córdova, por su invaluable dirección, paciencia y compromiso. Gracias por compartir su experiencia y por guiarme paso a paso; su apoyo, sus correcciones y sus sabios consejos fueron piezas clave para sacar adelante y culminar con éxito esta investigación.

A mi compañero de tesis, Kevin Isrrael Zamora Lozada. Gracias por tu inmensa dedicación, por las incontables horas de trabajo en equipo frente a la pantalla y por no rendirte cuando los retos parecían insuperables. Compartir este desafío contigo ha sido un verdadero privilegio; admiro tu

*esfuerzo y estoy seguro de que te espera un camino
lleno de grandes éxitos profesionales y personales.
¡Sigue adelante que no hay límites!*

*A mis amigos, los de toda la vida y los que este
camino universitario me regaló. Gracias por las
risas, por la paciencia en mis momentos de estrés,
por creer en mí y por ser ese apoyo incondicional
que aligera cualquier carga. Ustedes hicieron que
este viaje fuera mucho más llevadero y feliz; esta
victoria también es suya.*

*A quienes me brindaron herramientas y
colaboración técnica para hacer posible el
desarrollo de este proyecto enfocado en el
monitoreo cerebral, permitiendo que la ingeniería
y la inteligencia artificial se pongan al servicio de
un propósito mayor.*

A todos, de corazón, muchas gracias.

Kevin R. Gamboa Cornejo

DEDICATORIA

El presente trabajo lo dedico a:

Dios, por ser mi pilar inquebrantable en este camino. Tu gracia y bondad iluminaron mis días de incertidumbre y renovaron mis fuerzas al momento de sentir cansancio. Gracias por darme la constancia y la sabiduría para culminar esta meta. Este logro es el fiel reflejo de tu amor infinito y de tu propósito en mi vida.

Mis amados padres, quienes construyeron los cimientos de este sueño con su amor incondicional y sacrificios silenciosos. Mamá, tu ternura y palabras de aliento fueron mi refugio seguro; tu valentía es mi mayor inspiración. Papá, tus sabios consejos y tu rectitud me enseñaron el valor del esfuerzo; tu apoyo constante me dio el coraje para nunca rendirme. A ambos, mis grandes mentores, les dedico este título con profundo amor, esperando devolverles una parte del inmenso orgullo que me han brindado.

Emily, por tu apoyo fundamental durante todo este tiempo. Gracias por tu amor, tu paciencia y por caminar siempre a mi lado. Tu respaldo incondicional fue mi aliento en los días más agotadores y tu compañía, la motivación perfecta para alcanzar finalmente esta meta.

Kevin I. Zamora Lozada

AGRADECIMIENTO

Deseo expresar mi más profundo agradecimiento a quienes han sido un pilar fundamental en la culminación de este trabajo de titulación:

A Dios, por su infinita sabiduría y amor. Sin su fortaleza y guía para enfrentar los desafíos en los momentos más difíciles, este logro no habría sido posible.

A mis padres, cuyo amor incondicional, sacrificio y fe en mí me permitieron llegar hasta aquí. Gracias por brindarme el cariño y las enseñanzas que guiaron cada paso de este camino.

A Emily, por su inmenso amor, paciencia y respaldo incondicional. Gracias por ser mi motivación en los días de mayor exigencia y por celebrar conmigo cada pequeño éxito.

A mi compañero de proyecto, Kevin Gamboa, por compartir este camino. Gracias por las horas de investigación, por superar juntos los desafíos técnicos de nuestro prototipo y por hacer de este proceso una gran experiencia de equipo.

A mi tutor de tesis, el Ing. Patricio Córdova, por su firmeza, dedicación y conocimientos. Gracias por ser una guía comprometida en mi formación como Ingeniero en Telecomunicaciones y orientarme siempre en la dirección correcta.

A la Universidad Técnica de Ambato, por la confianza y el apoyo brindado mediante los

recursos esenciales para hacer realidad nuestro sistema.

Finalmente, a mis familiares y amigos por su constante aliento y energía positiva. A todos ustedes, mi profunda gratitud; sin su presencia, este viaje no habría sido posible.

Kevin I. Zamora Lozada

ÍNDICE GENERAL DE CONTENIDOS

PORTADA.....	i
APROBACIÓN DEL TUTOR.....	ii
AUTORÍA.....	iii
DERECHOS DE AUTORES	iv
APROBACIÓN DEL TRIBUNAL DE GRADO.....	v
DEDICATORIA.....	vi
AGRADECIMIENTO	vii
DEDICATORIA.....	ix
AGRADECIMIENTO	x
ÍNDICE GENERAL DE CONTENIDOS	xii
ÍNDICE DE TABLAS.....	xix
INDICE DE FIGURAS.....	xx
ÍNDICE DE ANEXOS.....	xxiii
RESUMEN EJECUTIVO	xxv
ABSTRACT	xxvi
CAPÍTULO I. MARCO TEÓRICO.....	1
1.1 Tema de investigación.....	1
1.1.1 Planteamiento del problema.....	1
1.2 Antecedentes investigativos	4

1.3 Fundamentación teórica	8
1.3.1 Sistema de adquisición de bioseñales (EEG)	8
1.3.2 Procesamiento de bioseñales y Estándares Técnicos	10
1.3.3 Sistema predictivo basado en Inteligencia Artificial y EEG.....	11
1.3.4 Tecnologías en neuroingeniería y Salud 4.0	12
1.3.5 Infraestructura de hardware biomédico.....	13
1.3.6 Monitoreo de salud inteligente.....	16
1.3.7 Digitalización Clínica en Ecuador	19
1.3.8 Necesidades y brechas de accesibilidad biomédica	20
1.3.9 Inteligencia Artificial y predicción neurológica	21
1.4 Objetivos	23
1.4.1 Objetivo general	23
1.4.2 Objetivos específicos	23
CAPÍTULO II. METODOLOGÍA.....	24
2.1 Materiales.....	24
2.2 Métodos.....	26
2.2.1 Modalidad de la investigación	27
2.2.2 Población y muestra	28
2.2.3 Recolección de información.....	29
2.2.4 Procesamiento y análisis de datos	30
2.3 Conformación y Procesamiento Multidimensional del Dataset Maestro.....	31

2.3.1 Origen de los Datos e Integración Multifuente	31
2.3.2 Filtro Topográfico y Calibración del Escudo de Artefactos	33
2.3.3 Aislamiento Temporal y Filtrado Frecuencial	33
2.3.4 Fusión de Características: Método de Welch y Parámetros de Hjorth.....	34
2.3.5 Consolidación de la Matriz Definitiva	35
2.4 Ensayo Clínico y Selección Empírica del Algoritmo Clasificador.....	35
2.4.1 Carga de Datos y Mitigación de la "Fuga de Datos" (Pipelines)	37
2.4.2 Configuración de los Modelos Competidores.....	38
2.4.3 Validación Cruzada Aleatoria y Métricas de Latencia	38
2.5 Generación de la Matriz de Resultados.....	39
2.6 Arquitectura del modelo neuro-computacional SVM.....	40
2.7 Arquitectura de Entrenamiento y Optimización del Modelo Predictivo (SVM) .	42
2.7.1 Intervención Clínica y Prevención de Fuga de Datos	44
2.7.2 Ajuste de Hiperparámetros y Ponderación de Clases	46
2.7.3 Evaluación y Congelamiento del Modelo para Producción	47
2.7.4 Resultados del Rendimiento Analítico del Modelo Predictivo (SVM).....	48
CAPÍTULO III. RESULTADOS Y DISCUSIÓN.....	51
3.1 Desarrollo de la Propuesta	51
3.1.1 Validación de la Arquitectura de Hardware y Telemetría	53
3.1.2 Mapeo Topográfico y Justificación de Canales	54
3.2 Análisis del contexto	54

3.2.1 Especificación de requisitos del sistema	54
3.3 Módulo de Procesamiento Digital y Mitigación del "Batch Effect"	55
3.4 Prototipado funcional e integración tecnológica.....	55
3.4.1 Evaluación del tiempo real y latencia computacional.....	56
3.5 Entrenamiento y Pruebas Funcionales del Modelo de Inteligencia Artificial.....	57
3.5.1 Partición Estratificada del Conjunto de Datos	57
3.5.2 Estrategias para el Manejo de Datos Clínicos Desbalanceados	58
3.5.3 Explicabilidad de la Inteligencia Artificial (XAI)	59
3.5.4 Transparencia Geométrica y Vectores de Soporte	59
3.6 Validación Clínica: Interpretación del Mapa Dinámico de Biomarcadores	60
3.6.1 Evaluación del Posible Diagnóstico.....	60
3.7 Marco Normativo y Regulatorio para Software como Dispositivo Médico (SaMD).....	61
3.7.1 Normativa Nacional y Protección de Datos Sensibles.....	61
3.7.2 Estándares Internacionales de Ingeniería Médica	62
3.7.3 Alineación de la Interfaz con el Marco Regulatorio	63
3.8 Parámetros y Estándares de la Interfaz Clínica (UX/UI).....	63
3.8.1 Ergonomía Visual y Psicología del Color (Estándar HIS).....	64
3.8.2 Arquitectura de Roles (RBAC) y Seguridad de la Información	64
3.8.3 Categorización como Sistema de Soporte (CDSS) e Integración Nacional.....	65
3.8.4 Privacidad desde el Diseño (Privacy by Design)	65

3.9 Gestión de Identidad, Autenticación y Control de Acceso (RBAC).....	66
3.9.1 Protocolos de Autenticación y Gestión de Sesión	66
3.9.2 Definición de Privilegios y Segregación de Funciones.....	66
3.9.3 Cumplimiento de Estándares Médicos de Acceso	68
3.10 Arquitectura del Pipeline de Procesamiento y clasificación Algorítmica ...	68
3.10.1 Adquisición y Preprocesamiento Espectral de Bioseñales.....	68
3.10.2 Extracción de Características Topográficas y Escalado Dimensional	69
3.10.3 Interferencia Multiclase mediante SVM y Emisión de Resultados.	69
3.11 Fundamentación Matemática y Procesamiento Digital	70
3.11.1 Métricas de la Señal y Técnica de Enventanado	70
3.11.2 Extracción de Biomarcadores y Parámetros Clínicos	71
3.11.3 Matriz de Correlación y Análisis del Espacio de Características	71
3.12 Viabilidad Computacional y Evaluación del Modelo	73
3.12.1 Costo Computacional y Eficiencia del Sistema	73
3.12.2 Métricas Robustas de Entrenamiento y Validación	74
3.13 Diseño Metodológico Clínico y Normativo	74
3.13.1 Protocolo de Adquisición Libre de Artefactos.....	74
3.13.2 Definición y Rol del Grupo de Control.....	75
3.13.3 Respaldo Normativo y Estándares (CDSS).....	75
3.14 Implementación del Sistema de Soporte a la Decisión Clínica (Aplicativo Web).....	75

3.14.1	Arquitectura de Seguridad y Control de Roles (RBAC).....	76
3.14.2	Módulo de Procesamiento y Escudo Dinámico de Artefactos.....	77
3.14.3	Renderizado Visual y Generación Automatizada de Anexos (Formulario 002)	
	77	
3.15	Caracterización demográfica y distribución de la muestra clínica experimental.....	78
3.16	Evaluación Operativa de la Interfaz Gráfica y Resultados Clínicos	81
3.16.1	Autenticación y Admisión del Paciente	81
3.16.2	Veredicto Computacional y Certeza Diagnóstica	83
3.16.3	Proyección Espacial de Biomarcadores	84
3.16.4	Trazado Temporal y Aislamiento de Artefactos Fisiológicos.....	84
3.16.5	Análisis de Densidad Espectral y Proporcionalidad de Ondas	87
3.16.6	Trazado Crudo y Evidencia Visual de Artefactos Fisiológicos	87
3.16.7	Impresión Computacional de Riesgo y Descargo Legal	89
3.17	Análisis de resultados	91
3.17.1	Matriz de Confusión de Pacientes Sanos	91
3.17.2	Matriz de Confusion de Pacientes con deterioro cognitivo leve.....	92
3.17.3	Matriz de Confusión de Pacientes con Riesgo de Parkinson	92
3.17.4	Interpretación de Resultados	93
3.17.5	Viabilidad Tecnológica y Potenciación del Hardware.....	94
3.17.6	Eficacia como Herramienta de Tamizaje Preventivo.....	95
3.18	Validación de Resultados	95

3.18.1 Validación de Resultados: Estado Sano.....	96
3.18.2 Validación de Resultados: Pacientes con MCI	97
3.18.3 Validación de Resultados: Pacientes con riesgo de Parkinson	98
3.18.4 Presupuesto	99
CAPÍTULO IV. CONCLUSIONES Y RECOMENDACIONES	102
4.1 Conclusiones	102
4.2 Recomendaciones.....	103
REFERENCIAS BIBLIOGRÁFICAS.....	105
ANEXOS.....	118

ÍNDICE DE TABLAS

Tabla 1. Normativas-estándares aplicables a la accesibilidad digital[32].....	11
Tabla 2. Comparativa de sistemas de adquisición EEG portátiles[39]	13
Tabla 3. Comparativa de plataformas de procesamiento para bioseñales[46]	15
Tabla 4. Materiales utilizados en el desarrollo del sistema neuro-computacional[84].	24
Tabla 5. Justificación técnica de los materiales del sistema predictivo[85]	25
Tabla 6. Organización del procedimiento de recolección de datos[89].	29
Tabla 7. Resultados definitivos de exactitud computacional por algoritmo	36
Tabla 8. Métricas de estabilidad de la telemetría inalámbrica[124]	53
Tabla 9. Requisitos funcionales y no funcionales del sistema[125]	55
Tabla 10. Desglose de latencia por etapas del proceso neuro-computacional[126] ..	56
Tabla 11. Costo Computacional	73
Tabla 12. Recursos económicos	101

INDICE DE FIGURAS

Figura 1. Sistema de adquisición e interfaz cerebro-computador[26].	9
Figura 2. Arquitectura Tecnológica del Diagnostico 4.0[35]	12
Figura 3. Monitoreo de Salud Integral[54].	17
Figura 4. Adopción de tecnología de salud digital y telemedicina[71].	20
Figura 5. Arquitectura de Inteligencia Artificial en el análisis clínico[79].	21
Figura 6. Casco Emotiv Insight 2.0[86]	26
Figura 7. Repositorios Multifuente	32
Figura 8. Configuración paramétrica	33
Figura 9. Función del filtrado	34
Figura 10. Algoritmo para el cálculo de descriptores geométricos en el dominio del tiempo.	34
Figura 11. Exportación final del Dataset Maestro	35
Figura 12. Separación de características y configuración de las cadenas de ejecución	37
Figura 13. Instanciación de las cinco arquitecturas de aprendizaje	38
Figura 14. Bucle de validación cruzada	39
Figura 15. Consolidación y tabulación de las métricas de exactitud de los algoritmos evaluados.	40
Figura 16: Arquitectura del modelo SVM[147]	41
Figura 17. Arquitectura del Pipeline de Procesamiento y Clasificación SVM[120].	44
Figura 18. Partición del conjunto de datos agrupada por paciente	45

Figura 19. Configuración del pipeline secuencial y optimización de hiperparámetros	47
Figura 20. Lógica de ejecución para la evaluación del rendimiento analítico en el conjunto de prueba aislado	47
Figura 21. Configuración del pipeline de entrenamiento global definitivo y serialización de archivos binarios (.pkl).....	48
Figura 22. Reporte de clasificación final evaluado	50
Figura 23. ISO 9241-210[123]	53
Figura 24. Matriz de Correlación[141]	72
Figura 25. Modulo de autenticación y segregación de perfiles de usuario	76
Figura 26. Motor de reportes PDF	78
Figura 27. Prueba de Pacientes y distribución de muestra experimental	80
Figura 28. Acceso al Sistema	82
Figura 29. Ficha de Admisión de Datos.....	82
Figura 30. Confirmación de protección de datos	83
Figura 31. Panel del Diagnostico Probabilístico	83
Figura 32. Mapa de dispersión cruzando los biomarcadores	84
Figura 33. Onda Delta	85
Figura 34. Onda Theta.....	86
Figura 35. Onda Alpha.....	86
Figura 36. Onda Beta	86
Figura 37. Onda Gamma	86

Figura 38. Tabla de densidad espectral de potencia.....	87
Figura 39. Trazado crudo nativo del dispositivo.....	88
Figura 40. Gráfico de Potencia de las ondas	89
Figura 41. Impresión del veredicto final y cláusula de protección legal	90
Figura 42. Reporte Clínico del paciente.....	90
Figura 43. Matriz de confusión de pacientes sanos[88]	91
Figura 44. Matriz de confusión de pacientes con MCI[88]	92
Figura 45. Matriz de confusión de pacientes con Riesgo de Parkinson[88]	93
Figura 46. Núcleo ARM Cortex-M4[144]	118
Figura 47. Núcleo ARM Cortex-M4[145]	119
Figura 48. TDK InvenSense ICM-20948[146]	120

ÍNDICE DE ANEXOS

Anexo A. Explicación de la Unidad de Procesamiento y Digitalización de Señales.	118
Anexo B. Identificación del Sistema en Chip (SoC) de Transmisión Inalámbrica..	119
Anexo C. Explicación de la Unidad de Medición Inercial para Mitigación de Artefactos	120
Anexo D. Protocolo de colocación ajuste y calibración del Casco.....	121
Anexo E. Fase Clínica y Adquisición de Bioseñales	124
Figura D1. Posicionamiento anatómico y alineación topográfica del dispositivo Emotiv Insight 2.0	121
Figura D2. Proceso de colocación y calibración de impedancia del dispositivo BCI Emotiv Insight 2.0.....	122
Figura D3. Proceso de colocación y calibración de impedancia del dispositivo BCI Emotiv Insight 2.0.....	122
Figura D4. Estación de monitoreo y telemetría de datos en tiempo real.	123
Figura D5. Aplicación estricta del protocolo de inmovilidad para mitigación de artefactos miogénicos.....	123
Figura E1. Interfaz de autenticación y control de acceso basado en roles (Investigador / Médico / Paciente).	124
Figura E2. Fase 1 del Protocolo de preparación e instrucciones clínicas en el portal del paciente.....	125
Figura E3. Fase 2 y 3 del Protocolo de preparación e instrucciones clínicas en el portal del paciente.	125

Figura E4. Fase 4 del Protocolo de preparación e instrucciones clínicas en el portal del paciente.....	126
Figura E5. Análisis Neuro-Computacional.	126
Figura E6. Interfaz de configuración técnica y supervisión algorítmica para el perfil de investigador	127
Figura E7. Interfaz de visualización de resultados y soporte a la decisión clínica para el perfil de médico neurólogo.	127
Figura E8. Anexo generado a la Historia Clínica Única.....	128

RESUMEN EJECUTIVO

La presente investigación nace ante la crisis global y local de las enfermedades neurodegenerativas, las cuales impresionan a más de 55 millones de personas a nivel mundial. En el contexto ecuatoriano, aproximadamente 100 000 personas sufren algún tipo de demencia, afrontando limitaciones diagnósticas debido al alto costo y la insuficiente disponibilidad de equipos especializados en provincias como Tungurahua. El objetivo general de este proyecto es desarrollar un prototipo electrónico de monitoreo cerebral en tiempo real que proporcione la detección temprana de estos estudios mediante el uso de técnicas de Inteligencia Artificial.

La metodología se enmarca en una investigación aplicada con enfoques bibliográfico-documental y experimental. El sistema diseñado integra hardware de bajo costo, incluyendo sensores de electroencefalografía EEG no invasivos y microcontroladores para la adquisición y transmisión inalámbrica de señales bioeléctricas. Para el procesamiento de datos, se efectúan algoritmos de aprendizaje automático (Machine Learning) y aprendizaje robusto (Deep Learning) orientados a determinar patrones neuronales anómalos asociados al deterioro cognitivo.

El desarrollo incluye una interfaz de visualización en tiempo real que faculta a los profesionales de la salud controlar la actividad cortical y recibir advertencias fundadas en los diagnósticos preliminares del modelo de IA. Como resultado, se obtiene una herramienta tecnológica accesible y portátil que reduce la brecha económica en el diagnóstico neurológico, promoviendo una atención médica más inclusiva y preventiva. Se concluye que la convergencia entre la neuroingeniería y la IA ofrece una viable solución para mejorar la calidad de vida de los pacientes mediante la intervención oportuna en las etapas iniciales de la enfermedad.

Palabras clave: Inteligencia artificial, electroencefalografía (eeg), enfermedades neurodegenerativas, monitoreo en tiempo real, biopotenciales, telemedicina.

ABSTRACT

The present research arises from the global and local problematic of neurodegenerative diseases, which affect more than 55 million people worldwide. In the Ecuadorian context, approximately 100,000 people suffer from some type of dementia, facing diagnostic limitations due to high costs and the low availability of specialized equipment in provinces such as Tungurahua. The general objective of this project is to develop an electronic prototype for real-time brain monitoring to facilitate the early detection of these pathologies through the use of Artificial Intelligence (AI) techniques.

The methodology is framed within applied research with bibliographic-documentary and experimental approaches. The designed system integrates low-cost hardware, including non-invasive electroencephalography (EEG) sensors and microcontrollers for the acquisition and wireless transmission of bioelectrical signals. For data processing, machine learning and deep learning algorithms are implemented to identify anomalous neuronal patterns associated with cognitive impairment.

The development includes a real-time visualization interface that allows health professionals to monitor cortical activity and receive alerts based on the preliminary diagnoses of the AI model. As a result, an accessible and portable technological tool is obtained that reduces the economic gap in neurological diagnosis, promoting more inclusive and preventive medical care. It is concluded that the convergence between neuroengineering and AI offers a viable solution to improve the quality of life of patients through timely intervention in the early stages of the disease.

Keywords: Artificial intelligence, electroencephalography (eeg), neurodegenerative diseases, real-time monitoring, biopotentials, telemedicine.

CAPÍTULO I. MARCO TEÓRICO

1.1 Tema de investigación

PROTOTIPO ELECTRÓNICO DE MONITOREO CEREBRAL EN TIEMPO REAL
CON ENFOQUE EN LA DETECCIÓN TEMPRANA DE ENFERMEDADES
NEURODEGENERATIVAS MEDIANTE TÉCNICAS DE INTELIGENCIA
ARTIFICIAL

1.1.1 Planteamiento del problema

La Organización Mundial de la Salud [1], la medicina actual se apoya cada vez mas en las telecomunicaciones y la inteligencia artificial para hacer frente al aumento de casos de demencia, esta es la base de salud inteligente. Para que el concepto funcione en la práctica se requiere sistemas de monitoreo electrónico, esta infraestructura es la que realmente permite conectar los sensores físicos con los servicios de diagnóstico a distancia. En conclusión, el buen manejo de las enfermedades neurodegenerativas depende de la capacidad de nuestras redes, si la red logra integrar todos esos datos en tiempo real, la intervención médica será oportuna.

Parra et al. [2] explican que la falta de infraestructura en los países en vías de desarrollo crea una gran brecha tecnológica en América Latina. Esto frena el acceso a servicios neurológicos. Sin equipos adecuados no hay diagnóstico temprano. El problema se refleja directamente a nivel local en Tungurahua. La escasez de alternativas de bajo costo deja a los adultos mayores sin opciones reales para un buen tratamiento.

Sin embargo, Mohamed et al. [3] enfatizan que la facilidad digital y el monitoreo mediante sensores portátiles son pilares primordiales para mitigar los retos diagnósticos presentes. Desde el punto de vista de las telecomunicaciones, esto implica el desarrollo de infraestructuras capaces de soportar plataformas de telemedicina que apliquen algoritmos de IA para gestionar señales biomédicas. La privación de estas soluciones técnicas genera desigualdades profundas en el acceso a la salud y retarda la identificación de síntomas críticos hasta etapas avanzadas de la enfermedad.

Pese a que la Alzheimer's Association [4] confirma en sus informes que la detección proactiva mediante biomarcadores es primordial para mejorar el pronóstico, en el entorno nacional aún predomina una gestión reactiva. Actualmente, la evaluación neurológica depende de métodos comunes costosos que restringen una respuesta automatizada ante la demanda creciente de la población. Esta falta de telemetría y análisis predictivo limita la competitividad del sistema sanitario ecuatoriano, provocando diagnósticos tardíos que afectan la autonomía de los pacientes.

En términos más generales, IEEE Reviews in Biomedical Engineering [5] manifiestan que el desarrollo del diagnóstico temprano mediante inteligencia artificial no puede concebirse sin una arquitectura robusta de adquisición y procesamiento de bioseñales como el EEG. La digitalización de la salud necesita redes estables y algoritmos de aprendizaje automatizado que permitan categorizar patrones cerebrales para la toma de decisiones clínicas. Este punto de vista técnico se alinea con el objetivo del proyecto, que busca integrar IA y sensores de bajo costo para mejorar la precisión diagnóstica en entornos con recursos limitados.

Pese a las capacidades tecnológicas, Leela et al. [6] defiende que el éxito del análisis de señales cerebrales a partir de dispositivos portátiles depende de la correcta aplicación de modelos de aprendizaje profundo (Deep Learning). La inexistencia de una red de procesamiento de datos en tiempo real en los centros de salud locales impide una gestión eficiente del bienestar del paciente. Esta situación desmiente las exigencias globales de sostenibilidad del sistema sanitario, puesto que, al no contar con sistemas inteligentes, se conserva un modelo médico que no cumple con las expectativas actuales.

Por lo tanto, Zangeneh Soroush et al. [7] consideran que la unificación de redes avanzadas y modelos de clasificación de señales cerebrales posibilitara una gestión médica basada en evidencia científica. Este tipo de conectividad apoyaría la toma de decisiones automatizada, optimizando el control de los flujos de información y la precisión del reconocimiento de anomalías neuronales. En definitiva, la aplicación de estas tecnologías consolidaría el vínculo entre innovación y desarrollo social,

fortaleciendo un ecosistema digital inclusivo que impulse la transformación de la medicina hacia un modelo preventivo.

Xu et al. [8] describe que la delimitación de investigación enfocados al procesamiento de señales EEG debe concentrarse en proporciones técnicas especializadas para afirmar su validez en aplicaciones de ingeniería. Por lo tanto, este proyecto se ubica en el área de Electrónica, bajo la línea de investigación de Electrónica, Telecomunicaciones y Sistemas de Control de la Universidad Técnica de Ambato. En cuanto al ámbito espacial y temporal, la investigación se ejecutará en la provincia de Tungurahua durante el periodo académico febrero – junio 2026, acotando los recursos al horizonte práctico del curso.

Hossain et al. [9] mencionan que la demostración de este tipo de proyectos radica en la necesidad de modernizar la gestión sanitaria mediante el uso de interfaces cerebro-computador de bajo costo. En términos teóricos, el estudio colabora al desarrollo de sistemas de monitoreo que sobrepasen las barreras económicas de los exámenes clínicos tradicionales. En el plano aplicado, la solución propuesta podría aplicarse en centros locales, fortaleciendo la atención automatizada y brindando herramientas complementarias a los profesionales de la salud para el seguimiento clínico preventivo.

Finalmente, Habibzadeh Tonekabony Shad et al. [10] afirman que el desarrollo de electrodos secos y sistemas portátiles permite registrar señales cerebrales fuera de laboratorios especializados, favoreciendo el monitoreo continuo. No obstante, Aviles et al. [11] y Panda et al. [12] concuerdan en que el éxito de estas respuestas basadas en IA depende de la estabilidad de la infraestructura de comunicación y la robustez de los algoritmos de extracción de características. Desde este punto de vista, la convergencia tecnológica posee el potencial de empoderar a los profesionales médicos, mejorando su capacidad diagnóstica y posicionándolos como protagonistas del desarrollo tecnológico médico regional.

1.2 Antecedentes investigativos

El desarrollo de sistemas de monitoreo biomédico basados en Inteligencia Artificial (IA) y el procesamiento de señales de Electroencefalografía (EEG) ha transformado significativamente la gestión de la salud neurológica a nivel global, promoviendo diagnósticos más tempranos, precisos y accesibles[13]. Entre los años 2020 y 2025, diversas investigaciones han evidenciado el potencial de estas tecnologías para optimizar la adquisición de biopotenciales, mejorar la clasificación de patologías [14] y fortalecer la infraestructura digital de los centros de salud. En este contexto, el presente estudio se fundamenta en el análisis de artículos científicos, revistas indexadas y proyectos tecnológicos que abordan la integración de redes neuronales y hardware de bajo costo[15], con el fin de sustentar la propuesta técnica dirigida al desarrollo de un prototipo para la detección de enfermedades neurodegenerativas en la provincia de Tungurahua.

En este ámbito, el estudio desarrollado por Palumbo et al.[16] propone un marco integrado que combina sensores portátiles y algoritmos de aprendizaje profundo para el monitoreo continuo de la salud cerebral. Mediante un diseño experimental y una validación con prototipos de bajo consumo, los autores demostraron que la convergencia tecnológica mejora significativamente la detección de anomalías en tiempo real. Los resultados subrayan que la integración de sistemas embebidos y modelos de clasificación no solo es viable, sino que aporta sostenibilidad al ecosistema médico, ofreciendo así una arquitectura de referencia técnica para el uso de IA en entornos no clínicos.

Por su parte, Muresanu et al.[17] realizaron una revisión crítica sobre las aplicaciones de Machine Learning en la clasificación de señales EEG, poniendo énfasis en sus capacidades y limitaciones para el diseño de soluciones en ingeniería biomédica. Objetivo: sintetizar la literatura reciente sobre el preprocesamiento de señales, identificando áreas maduras como la eliminación de artefactos y vacíos en la interpretación automatizada. Metodología: revisión sistemática de artículos indexados y clasificación temática de arquitecturas de redes neuronales. Resultados: la IA ha demostrado aumentar la precisión diagnóstica en enfermedades como el Alzheimer,

pero existen brechas en la interoperabilidad de hardware. Conclusión: la evidencia apoya los beneficios técnicos de la IA, pero recomienda estandarizar los protocolos de adquisición de datos. Aporte al estudio: fundamenta la necesidad de evaluar la compatibilidad entre los sensores EEG y los algoritmos de clasificación al diseñar el prototipo local.

En el contexto del monitoreo neurológico, Kirkpatrick et al.[18] exploraron cómo las tecnologías de sensores portátiles mejoran la calidad de vida de los pacientes y fortalecen la capacidad de respuesta de los sistemas de salud en entornos rurales. Objetivo: analizar cómo los atributos técnicos de los sensores EEG influyen en la detección temprana de trastornos cognitivos. Metodología: estudio empírico basado en pruebas de campo con una muestra de adultos mayores, complementado con análisis estadístico de la estabilidad de la señal. Resultados: se evidenció que la información en tiempo real y la portabilidad incrementan la eficacia del seguimiento clínico; además, la reducción de ruido electrónico resulta un factor determinante. Conclusión: la inversión en dispositivos de monitoreo accesibles mejora la competitividad sanitaria y refuerza la prevención. Aporte al estudio: este trabajo valida que el uso de información en tiempo real y análisis automatizado planteado en la propuesta puede aumentar la precisión diagnóstica en Tungurahua.

La acelerada convergencia entre la IA y las redes móviles de quinta generación (5G) ha permitido servicios médicos más conectados y predictivos. En esta línea, Kirkpatrick et al. [18] analizan el papel del IoT médico reforzado por algoritmos de aprendizaje profundo como base para aplicaciones de baja latencia en entornos hospitalarios inteligentes. Objetivo: explorar el potencial del procesamiento distribuido para habilitar el monitoreo cerebral remoto y análisis predictivo. Metodología: propuesta de arquitecturas integradas apoyada en simulaciones de rendimiento de red y estudios de caso de telemedicina. Resultados: se evidencia que la arquitectura IA + IoT permite una gestión eficiente mediante telemetría en tiempo real y soporte para alertas médicas automáticas. Conclusión: el despliegue de redes estables constituye un habilitador fundamental para la digitalización de la neurología al reducir la latencia de diagnóstico. Aporte al estudio: esta revisión aporta criterios

esenciales sobre la capacidad de red y la seguridad de transmisión que se implementarán en el prototipo electrónico.

En el país ecuatoriano, la accesibilidad tecnológica constituye un componente esencial para la inclusión de pacientes con movilidad reducida en el diagnóstico neurológico. En esta línea, Mi et al. [19] desarrollaron un estudio sobre el diseño de interfaces cerebro-computador para el apoyo en la salud, con el propósito de analizar el nivel de cumplimiento de los sistemas nacionales respecto a estándares de usabilidad. Objetivo: evaluar el grado de accesibilidad de los dispositivos médicos locales frente a pautas internacionales, identificando barreras técnicas. Metodología: auditoría de análisis funcional y revisión manual de prototipos experimentales, complementada con entrevistas a especialistas neurológicos. Resultados: se detectaron deficiencias en la ergonomía de los sensores y la falta de interfaces gráficas intuitivas para el personal de salud. Conclusión: la inclusión digital sanitaria requiere una estrategia que combine diseño universal y adopción de tecnologías portátiles. Aporte al estudio: proporciona evidencia relevante para el diseño del módulo de visualización propuesto, destacando la importancia de incorporar guías visuales claras.

La integración de sistemas electrónicos ha impulsado soluciones interactivas que optimizan la gestión de información clínica. Bajo este enfoque, Appriou et al.[20] analizaron el uso de microcontroladores y plataformas de código abierto como antecedente tecnológico para fundamentar el diseño de sistemas de adquisición de bioseñales. Metodología: la investigación se enmarca en un enfoque tecnológico basado en el análisis funcional de hardware como Arduino y Raspberry Pi para el procesamiento de EEG. Resultados: el estudio permitió reconocer que la arquitectura modular favorece la interacción eficiente entre hardware y software, logrando una visualización dinámica de la actividad cortical. Conclusión: la integración de dispositivos programables y protocolos de comunicación inalámbrica constituye una base sólida para el desarrollo de sistemas médicos. Aporte relevante: demuestra cómo los principios de control y visualización de datos pueden evolucionar hacia soluciones de monitoreo cerebral, ofreciendo una guía tecnológica para diseñar el sistema conectado en la ciudad de Ambato.

La incorporación de algoritmos de reconocimiento de patrones ha transformado la forma en que los médicos interpretan las bioseñales en tiempo real. Objetivo: analizar el proyecto desarrollado por Aljarallah et al. [21] sobre la mejora en la clasificación de trastornos neurológicos a fin de identificar aportes aplicables al diseño de prototipos basados en IA. Metodología: revisión técnica de sistemas que integran máquinas de soporte vectorial (SVM) para ofrecer diagnósticos personalizados. Resultados: el proyecto permitió comprobar que la integración de técnicas de extracción de características mejora significativamente la precisión al proporcionar datos contextuales del estado neuronal del paciente. Asimismo, el sistema optimizó la gestión del flujo de datos durante las pruebas clínicas. Conclusión: la combinación de IA y análisis de señales constituye una herramienta clave para la innovación en la salud preventiva. Aporte relevante: aporta un modelo de referencia para el diseño del software de la tesis, validando la posibilidad de aplicar el diagnóstico automatizado sin requerir equipos hospitalarios de gran escala.

La digitalización de la salud mediante plataformas interactivas ha fortalecido la relación entre ingeniería y medicina. Objetivo: analizar el proyecto desarrollado por Habibzadeh Tonekabony Shad et al. [10] orientado al diseño de electrodos secos para sistemas de monitoreo cerebral interactivo, con el fin de identificar estrategias aplicables en Ecuador. Metodología: investigación aplicada empleando metodologías ágiles para gestionar el proceso de desarrollo de hardware y software en lenguajes como Python. Resultados: la plataforma desarrollada integró un entorno de navegación intuitivo compatible con múltiples dispositivos. Su diseño permitió el acceso ágil a la información de biopotenciales y mejoró la interacción entre el técnico y el equipo. Conclusión: la combinación de frameworks de desarrollo modernos con sensores no invasivos constituye una estrategia efectiva para el diseño de plataformas médicas. Aporte relevante: aporta una guía tecnológica para la carrera de Telecomunicaciones al mostrar cómo la sinergia entre la programación multiplataforma y la gestión en tiempo real fortalece la propuesta de monitoreo inteligente.

Por último, el estudio de los antecedentes investigativos demuestra que la incorporación de tecnologías inteligentes como la IA, el procesamiento de señales EEG y las redes inalámbricas ha transformado significativamente la gestión

neurológica en distintos contextos. Los estudios revisados exponen cómo los sistemas de adquisición de bioseñales y las herramientas de aprendizaje profundo permiten perfeccionar la accesibilidad y eficiencia de los servicios de salud preventiva. Además, resaltan la importancia de infraestructuras robustas y estándares de usabilidad para respaldar diagnósticos confiables y de alto rendimiento[22]. Estos hallazgos ofrecen una base conceptual y tecnológica sólida para el desarrollo del prototipo de monitoreo cerebral propuesto en la presente investigación.

1.3 Fundamentación teórica

La digitalización en el área de la salud ha evolucionado significativamente con la integración de la Inteligencia Artificial (IA) y el procesamiento de bioseñales mediante tecnologías portátiles[23], lo que ha permitido la automatización de diagnósticos, la personalización del monitoreo y la optimización en la detección de enfermedades neurodegenerativas[24], esta sección desarrolla los conceptos clave que sustentan la investigación, proporcionando un análisis teórico de los elementos biomédicos y computacionales involucrados.

1.3.1 Sistema de adquisición de bioseñales (EEG)

Un sistema de adquisición electroencefalográfica (EEG) es una plataforma tecnológica diseñada para facilitar la medición bidireccional de la actividad eléctrica cerebral y el sistema informático, permitiendo la digitalización y gestión de datos en tiempo real. Estos sistemas son fundamentales en aplicaciones clínicas que requieren participación y monitoreo activo o en estado de reposo del paciente [25].

a. Organización de la experiencia clínica y el protocolo de reposo

La experiencia clínica en el ámbito médico se refiere a la percepción general que tiene un paciente y el especialista al interactuar con el equipo de diagnóstico. La optimización de esta experiencia busca mejorar la comodidad y accesibilidad, considerando las limitaciones motoras de adultos mayores. Una interfaz de adquisición

bien diseñada, con un protocolo claro para la toma de datos en estado de reposo, aumenta significativamente la calidad de la señal y la fidelidad del diagnóstico [25].

En la Figura 1 se puede observar las etapas de adquisición, procesamiento, clasificación y posible diagnóstico de la interfaz cerebro-computador.




Figura 1. Sistema de adquisición e interfaz cerebro-computador[26].

En los últimos años, el diseño de dispositivos de adquisición ha adquirido un papel estratégico dentro de las plataformas de salud inteligente, ya que un diseño efectivo no solo se centra en la electrónica, sino en la creación de entornos libres de estrés para el paciente. Al respecto, Craik et al. [24] señalan que el diseño centrado en el usuario debe basarse en una comprensión profunda de la neurofisiología, integrando metodologías de medición estandarizadas. En este sentido, la organización de la captura implica estructurar los protocolos de pacientes en estado de reposo de manera coherente, garantizando que el flujo de datos carezca de artefactos musculares severos. Por su parte, Yuan et al. [27] destacan que una experiencia bien planificada no solo mejora la usabilidad, sino que fortalece la confiabilidad de los datos recolectados a largo plazo.

- **Diseño de protocolos inclusivos:** en el sistema de monitoreo inteligente propuesto, la preparación del paciente en estado de reposo asegura que la señal base del cerebro se estabilice, facilitando la interacción de personas con deterioro cognitivo leve o Parkinson, alineándose con las normativas internacionales de bioética [28].
- **Recomendaciones diagnósticas basadas en IA:** a través del análisis de datos en tiempo real, el sistema puede ofrecer alertas clínicas, notificaciones sobre

asimetrías hemisféricas o sugerencias de revisión según las frecuencias cerebrales del paciente, mejorando la eficiencia del especialista [29].

b. Plataforma de hardware accesible y adaptable

Una plataforma de hardware accesible y adaptable es aquella que ha sido diseñada para ser utilizada por el mayor número posible de centros médicos, independientemente de su infraestructura o el presupuesto que empleen, esto implica adherirse a estándares de telemetría y utilizar un diseño de electrodos que permita ajustarse a diferentes morfologías craneales. La accesibilidad tecnológica es esencial para garantizar que las poblaciones vulnerables puedan interactuar eficazmente con el sistema [30].

Además, desarrollar una plataforma que sea verdaderamente inclusiva impulsa la equidad sanitaria, eliminando barreras de alto costo en exámenes como la resonancia magnética, colaborando a diagnósticos tempranos más humanos y sostenibles.

1.3.2 Procesamiento de bioseñales y Estándares Técnicos

La capa de procesamiento de datos en sistemas biomédicos representa el entorno donde convergen el hardware sensorial y la matemática computacional. El diseño de este procesamiento se rige por principios de integridad de la información médica, garantizando que los entornos digitales filtren, operen y analicen las señales de forma robusta. En el ámbito de arquitecturas que integran IA y sensores portátiles, estos estándares son críticos para asegurar la correcta clasificación de patologías [31].

El referente internacional para validar la calidad de estas señales recae en la correcta identificación de las bandas de frecuencia clínica. Estas normativas establecen criterios técnicos mínimos que permiten la estandarización médica [31].

Tabla 1. Normativas-estándares aplicables a la accesibilidad digital[32]

Banda de Frecuencia	Rango Técnico	Implicación en el Sistema con IA (MCI y Parkinson)
Delta	1 - 4 Hz	Un aumento anómalo en estado de reposo o vigilia indica posible daño estructural cognitivo.
Theta	4 - 8 Hz	Su incremento en zonas frontales es un biomarcador clave para el Deterioro Cognitivo Leve (MCI).
Alfa	8 - 13 Hz	La ralentización de su frecuencia pico es un indicador temprano crítico de la enfermedad de Parkinson.
Beta	13 - 30 Hz	Desincronización y alteraciones rítmicas vinculadas a fallos motores en etapas de neurodegeneración.
Gamma	30 - 50 Hz	Reducción severa en la conectividad durante el procesamiento de memoria y funciones ejecutivas complejas.

Para estructurar el sistema predictivo fue indispensable definir los rangos de operación exactos, en la Tabla 1 detalla los estándares de frecuencia que usaron para el diseño y la explicación de características de señales.

a. Filtros digitales y extracción de características

El filtrado digital se define como una metodología matemática que busca eliminar el ruido electromagnético sin comprometer la información clínica de las neuronas. Esta filosofía no se limita a la corrección, sino que implementa características de optimización como la Densidad Espectral de Potencia (PSD) mediante el método de Welch [33].

Desde la perspectiva de la bioingeniería, el análisis inclusivo de la señal aprovecha la diversidad de ratios clínicos como Theta/Alfa o TAR para generar bases de datos más robustas. Al integrar la normalización de la señal Z-score desde las etapas iniciales, se logra una fidelidad mejorada: sistemas que no solo cumplen con la normativa, sino que resultan más precisos en situaciones de análisis complejas [2].

1.3.3 Sistema predictivo basado en Inteligencia Artificial y EEG

Un sistema predictivo basado en IA y EEG integra la capacidad de análisis y aprendizaje del machine learning con la red de sensores biomédicos, los micro voltajes recopilados por el casco neuronal son procesados por algoritmos estadísticos para que

el sistema pueda tomar decisiones probabilísticas, anticipar el declive cognitivo y ofrecer un diagnóstico preliminar [11].

Esta definición encaja a la perfección con lo que buscamos. El prototipo no solo lee datos crudos, sino su trabajo real es extraer características y analizar esos patrones ocultos en las señales cerebrales.

1.3.4 Tecnologías en neuroingeniería y Salud 4.0

La Salud 4.0 representa la integración de las tecnologías emergentes en el sector médico, impulsando una transformación digital basada en la conectividad inteligente y la automatización diagnóstica, este paradigma se caracteriza por la aplicación de la inteligencia artificial, la microelectrónica y el análisis de datos masivos. Dichas tecnologías como se muestran en la Figura 2, permiten la evaluación dinámica del paciente en estado de reposo, facilitando la identificación clínica adaptada a las necesidades individuales [34] .



Figura 2. Arquitectura Tecnológica del Diagnostico 4.0[35]

a. *Arquitectura tecnológica del diagnóstico 4.0*

Se concibe como un ecosistema digital interconectado que integra biosensores con plataformas de software. Este modelo se estructura en tres niveles fundamentales [34]:

- **Nivel de adquisición sensorial:** sustentado por cascos EEG con electrodos de alta sensibilidad, sistemas de amplificación y módulos de transmisión inalámbrica

(Bluetooth Low Energy), este nivel garantiza la conectividad y el flujo continuo de biopotenciales [34].

- **Nivel de procesamiento computacional:** compuesto por entornos de programación (como Python) e inteligencia artificial que procesan los datos crudos. Este nivel permite la generación de características matemáticas aplicadas a la predicción de la enfermedad [36].
- **Nivel de aplicación clínica:** en el cual se desarrollan las interfaces orientadas al especialista médico. Incluye la visualización de series temporales y métricas de calidad de señal que articulan la toma de decisiones [36].

1.3.5 Infraestructura de hardware biomédico

La infraestructura de hardware biomédico se refiere a la integración de sensores de captura y sistemas de comunicación en el diseño de prototipos diagnósticos. En el ámbito neurológico, esto abarca la implementación de electrodos en zonas corticales clave bajo el sistema internacional 10-20, contribuyendo a un entorno médico más eficiente[37].

Para la implementación de la capa de percepción eléctrica, la selección del hardware resulta determinante. En el desarrollo de este prototipo se optó por evaluar el casco neuronal Emotiv Insight 2 frente a otros estándares del mercado, con el fin de ponderar factores como la portabilidad inalámbrica frente a la resolución de la señal[38]. La Tabla 2 detalla las especificaciones técnicas comparativas de sistemas de adquisición EEG portátiles.

Tabla 2. Comparativa de sistemas de adquisición EEG portátiles[39]

Características	Emotiv Insight 2	NeuroSky MindWave
Canales	5 (Multicanal: AF3, AF4, T7, T8, Pz)	1 (Frontal: Fp1)
Frecuencia Muestreo	128 Hz	512 Hz
Tipo de Sensor	Polímero hidrofílico (Semi-seco)	Acero inoxidable (Seco)
Conectividad	Bluetooth Low Energy (BLE)	Bluetooth clásico
Precio Aprox.	\$400 - \$500 USD	\$100 - \$150 USD

El casco Emotiv Insight 2 destaca por integrar 5 canales distribuidos estratégicamente para capturar la actividad prefrontal, temporal y parietal, una característica técnica superior que permite procesar el control motor y la memoria[40]. A diferencia de las diademas monocanal, este modelo facilita la extracción de asimetrías cerebrales, optimizando la base de datos para la Inteligencia Artificial[41].

a. Monitoreo inteligente de bioseñales

En el sector de la salud y la bioingeniería, implica la supervisión y el seguimiento en tiempo real de diversos indicadores neurofisiológicos relevantes para la gestión clínica y el bienestar de los pacientes. Esto incluye el control de las potencias de las bandas cerebrales, la calidad de la señal y la detección de asimetrías hemisféricas, utilizando sensores no invasivos y análisis de datos [42]. Este monitoreo proactivo posibilita una respuesta médica rápida ante modificaciones imperceptibles, una gestión más eficaz de los recursos hospitalarios y la capacidad de anticipar el deterioro cognitivo, colaborando a tratamientos más oportunos y precisos.

El monitoreo inteligente biomédico combina redes de sensores portátiles con técnicas de procesamiento de datos y algoritmos de inteligencia artificial para captar variables electroencefalográficas en tiempo real. Estos sistemas permiten tanto la detección temprana de incidencias neurológicas como el seguimiento continuo del paciente, optimizando los recursos clínicos y reduciendo los tiempos de espera [43]. El acoplamiento de fuentes heterogéneas y el análisis en tiempo real modifican la información cruda en indicadores médicos operativos y decisiones automatizadas. Por consecuencia, es importante el monitoreo inteligente por ser la base operacional para optimizarla precisión y eficiencia al momento de generar un posible diagnóstico para enfermedades neurodegenerativas.

Para la implementación de la capa de procesamiento y transmisión visual en sistemas de Edge Computing médico (computación en el borde), la selección del hardware y la plataforma de ejecución resulta determinante en el rendimiento del algoritmo de detección. Existen diferencias arquitectónicas significativas entre el procesamiento local en una estación de trabajo (PC), el uso de microordenadores y los microcontroladores embebidos[44]. En el desarrollo de este prototipo se optó por

ejecutar los algoritmos de IA en un entorno local (PC con Python) frente a otros estándares de hardware embebido, con el fin de ponderar factores como la capacidad de procesamiento de la librería Scikit-Learn frente a la latencia de transmisión de datos[45]. La Tabla 3 detalla las especificaciones técnicas comparativas de tres plataformas de procesamiento comunes en proyectos de ingeniería.

Tabla 3. Comparativa de plataformas de procesamiento para bioseñales[46]

Características	Computadora Local (PC - Python)	Raspberry Pi 4 Model B	Microcontrolador (ESP32)
Arquitectura de Procesamiento	Multizona (x64 / ARM64 de alto rendimiento)	ARM Cortex-A72 (Quad-core)	Xtensa Dual-core 32-bit
Memoria RAM	8 GB - 32 GB+	2 GB - 8 GB	520 KB SRAM
Conectividad con Casco EEG	Bluetooth Integrado / Dongle BLE	Wi-Fi / Bluetooth 5.0 BLE	Wi-Fi / Bluetooth 4.2 BLE
Soporte para IA (Random Forest)	Nativo (Scikit-Learn, Pandas, NumPy)	Compatible (requiere optimización de entorno)	Limitado (MicroPython / TensorFlow Lite)
Latencia de Procesamiento	Muy Baja (Procesamiento en tiempo real fluido)	Media (Depende de la carga térmica)	Alta (Para algoritmos de ensamble complejos)
Visualización (Interfaz Gráfica)	Excelente (Soporte para PyQt, Tkinter)	Buena (Soporte para monitores HDMI)	Nula / Externa (Requiere servidor web)
Almacenamiento de Datos (Logs)	Discos SSD (Terabytes de capacidad)	Tarjeta MicroSD (Limitada por ciclos de escritura)	Memoria Flash (Megabytes)
Costo de Implementación	Equipo preexistente (Costo cero añadidos)	\$80 - \$120 USD	\$10 - \$20 USD

La ejecución del modelo en una Computadora Local (PC) destaca por integrar una capacidad de procesamiento superior que permite ajustar y entrenar el modelo Random Forest sin restricciones de memoria, una característica técnica fundamental que permite manejar múltiples hilos de ejecución simultáneos para la captura, el filtrado y la clasificación de la señal[47]. A diferencia de los microcontroladores como el ESP32, este modelo facilita la visualización gráfica en tiempo real, optimizando la experiencia del especialista. Además, su compatibilidad nativa con librerías de ciencia de datos garantiza una detección constante y fiable en los entornos clínicos, mitigando el riesgo de pérdida de paquetes de datos biomédicos[48].

b. Conectividad digital y telemetría médica

Las redes de telemetría conectadas son la infraestructura de comunicación esencial que interconecta todos los elementos de un sistema de salud inteligente. Esto incluye redes de alta velocidad, Wi-Fi local y tecnologías del Internet de las Cosas Médicas (IoMT) que permiten el intercambio de datos en tiempo real entre el casco neuronal, la computadora y las bases de datos de los pacientes [49]. Una conectividad robusta es fundamental para el desarrollo de la Salud 4.0, ya que facilita el funcionamiento del software de monitoreo, la transmisión de bioseñales sin latencia y la comunicación fluida para emitir un posible diagnóstico certero[50].

La conectividad digital abarca la infraestructura de telecomunicaciones y las arquitecturas de red que aseguran comunicación fiable y baja latencia entre los dispositivos biomédicos. Una conectividad robusta es requisito indispensable para aplicaciones críticas y para reducir la brecha digital en centros de salud. Además, la convergencia de redes de alta velocidad permite el análisis continuo de algoritmos pesados y la coordinación eficaz de los historiales médicos [51]. Sin protocolos de transmisión estables (como Bluetooth Low Energy) no es posible escalar servicios inteligentes que dependan del flujo continuo de voltaje cerebral en tiempo real[52].

1.3.6 Monitoreo de salud inteligente

Se entiende como el uso integrado de tecnologías digitales: IA, big data, Internet de las Cosas Médicas (IoMT), comunicaciones móviles y plataformas ubicuas, para ofrecer servicios clínicos más conectados, personalizados, eficientes y sostenibles. Un sistema de monitoreo inteligente no solo recopila datos y bioseñales, sino que las transforma en información accionable que mejora la gestión del historial, la experiencia del paciente y la toma de decisiones por parte de los especialistas médicos [42]. Esta visión sitúa al paciente y al entorno hospitalario en un ecosistema digital coordinado que facilita la interacción en tiempo real y la gobernanza sanitaria adaptativa [43].

Por consiguiente, en la Figura 3 observamos la referencia sobre el Monitoreo Inteligente, este es un concepto integral que busca la transformación de los centros de salud mediante la aplicación intensiva de las Tecnologías de la Información y

Comunicación (TIC), la innovación y la sostenibilidad. Su objetivo es mejorar la eficiencia operativa y la precisión del posible diagnóstico, a través de una gestión más eficiente de los recursos y un seguimiento automatizado[53].



Figura 3. Monitoreo de Salud Integral[54].

a. Información contextualizada para la toma de decisiones del especialista

Se refiere a datos y conocimiento presentados al médico en función de su contexto inmediato, como: potencias espectrales extraídas, historial previo, condiciones del paciente en reposo y métricas de asimetría cerebral, de modo que la información resulte pertinente y oportuna. Los sistemas inteligentes combinan fuentes (sensores EEG, bases de datos clínicas) y técnicas analíticas para recomendar acciones concretas que facilitan decisiones informadas y en tiempo real [49]. La evidencia reciente muestra que la contextualización incrementa la utilidad percibida de las predicciones algorítmicas y mejora la rapidez y calidad del posible diagnóstico [55].

La toma de decisiones clínicas se refiere a la capacidad de un sistema de proporcionar datos relevantes y oportunos que se adaptan al momento específico del examen, utilizando análisis predictivos[56]. Esta información ayuda al neurólogo a optimizar la evaluación y anticipar el comportamiento de las patologías neurodegenerativas (MCI y Parkinson)[57].

b. Optimización de la experiencia médica mediante diseño interactivo

Implica el diseño de entornos y herramientas digitales que se adaptan a las necesidades operativas del personal médico, mitigando la carga cognitiva. Para lograr esto en el despliegue del software mediante el framework Streamlit, se ha inyectado un bloque de CSS personalizado que aplica una paleta de colores cuidadosamente seleccionada (verde agua, palo de rosa y celeste suave). Esta implementación se fundamenta en la psicología del color para interfaces clínicas, la cual busca reducir drásticamente la fatiga visual del operador frente a las pantallas[58]. Estudios recientes muestran que el diseño de interfaces serenas y contextualizadas mejora la concentración, la percepción de valor de la herramienta y la eficiencia general durante la validación del posible diagnóstico [59].

c. Seguridad algorítmica y control de acceso interactivo

En entornos médicos inteligentes, el despliegue de herramientas digitales debe asegurar la estricta confidencialidad de la información y proteger el entorno de ejecución. Para garantizar esta exclusividad y seguridad, el desarrollo del prototipo implementa un sistema avanzado de Variables de Estado de Sesión (st.session_state). Este mecanismo crea una "bóveda de seguridad" al inicio de la aplicación interactiva; si el operador no ingresa las credenciales correctas y autorizadas, el código detiene su ejecución de manera absoluta y bloquea el acceso a la plataforma de análisis [60]. La literatura reciente enfatiza que la protección algorítmica no es solo una obligación ética y legal en el manejo de historiales, sino un componente estratégico que fortalece la integridad de los posibles diagnósticos generados [61].

d. Tecnología del monitoreo biomédico

La telemedicina inteligente se define como la aplicación integrada de comunicaciones, sensórica, IoT, IA y plataformas ubicuas para convertir datos brutos en servicios médicos. El concepto ha sido desarrollado por investigadores que enfatizan la interoperabilidad entre actores del ecosistema de salud [62]. En la actualidad, la convergencia entre inteligencia artificial y sistemas ciberfísicos (como los cascos BCI) potencia la automatización de procesos[63]. Estas capacidades tecnológicas permiten

anticipar patrones patológicos, optimizar recursos hospitalarios y fortalecer la resiliencia operativa de los centros de salud[64].

e. Redes inalámbricas en bioingeniería

La infraestructura de redes inalámbricas constituye la columna vertebral del Monitoreo 4.0, proporcionando conectividad de baja latencia y alta capacidad necesaria para la transmisión continua de sensores neurológicos y servicios en tiempo real. Las bases de diseño de protocolos como Bluetooth Low Energy (BLE) abordan desde la propagación del enlace hasta la adaptación en entornos ruidosos. Estas soluciones son esenciales para garantizar la calidad de servicio (QoS) en la extracción continua de microvoltios [65].

f. Protocolos de comunicación y seguridad de datos

Los protocolos de comunicación son fundamentales para la interoperabilidad en sistemas médicos distribuidos. La elección correcta del mecanismo de transmisión condiciona la robustez de aplicaciones como la monitorización cerebral, asegurando que los paquetes de datos lleguen a la etapa de procesamiento matemático sin pérdidas que puedan alterar el posible diagnóstico [66].

g. Algoritmo para el análisis computacional

El análisis de datos clínicos utiliza técnicas de aprendizaje automático para extraer patrones, aplicando procesos de Normalización Z-Score y el Método de Welch. Los modelos estadísticos (como Support Vector Machines con Kernel RBF o Random Forest) son los pilares metodológicos para evaluar las decenas de variables extraídas de las bandas EEG, consolidando una predicción analítica de alta precisión [24].

1.3.7 Digitalización Clínica en Ecuador

El panorama sanitario en el territorio ecuatoriano enfrenta un reto significativo respecto a la modernización de sus equipos de evaluación neurológica. La inversión en software predictivo es aún emergente[67], lo que estanca la transición completa hacia los modelos integrales de la "Salud 4.0"[68].

A pesar de las limitaciones económicas y de conectividad en zonas rurales, existe un interés genuino por parte de los profesionales para integrar sistemas de apoyo algorítmico en sus consultas[69]. Tuz-Tapia et al. [70] sugieren en su análisis reciente de desafíos éticos y tecnológicos en Ecuador que la adopción de arquitecturas computacionales de código abierto emerge como una alternativa altamente viable. En la Figura 4 observamos la adopción de tecnología de salud digital y telemedicina, esto permite a los hospitales procesar bioseñales complejos y emitir un posible diagnóstico sin depender de licencias de software privativas de alto costo, superando las barreras geográficas.




Figura 4. Adopción de tecnología de salud digital y telemedicina[71]

1.3.8 Necesidades y brechas de accesibilidad biomédica

Para comprender las limitaciones del entorno clínico actual, es imperativo analizar las barreras físicas y tecnológicas que impiden la masificación de los estudios electroencefalográficos[72]. Averos Durango et al. [73] evidencian en sus estudios sobre la brecha tecnológica hospitalaria en Ecuador que el acceso a pruebas tempranas está severamente restringido debido a los siguientes factores críticos:

- Dependencia de instalaciones estáticas: Los polígrafos EEG tradicionales exigen habitaciones aisladas de interferencias electromagnéticas, una logística financieramente inviable para subcentros de salud periféricos[74].

- Escasez de hardware no invasivo: La falta de dispositivos portátiles limita la capacidad de realizar mediciones ágiles, excluyendo a pacientes de la tercera edad con problemas de movilidad que no pueden trasladarse a hospitales de tercer nivel[75].
- Déficit de especialistas en neurofisiología: La interpretación visual de los ritmos cerebrales es una tarea exhaustiva que requiere pericia médica. La carencia de neurólogos prolonga los tiempos de espera de los pacientes, retrasando drásticamente la entrega de un posible diagnóstico oportuno frente a enfermedades degenerativas[75].

Frente a esta realidad, la automatización del análisis de bioseñales se vuelve no solo una innovación técnica, sino una necesidad social para democratizar la atención médica preventiva[76].

1.3.9 Inteligencia Artificial y predicción neurológica

En la Figura 5, el procesamiento computacional mediante modelos de aprendizaje automático ha transformado radicalmente el enfoque de las ciencias médicas en el país. En el campo de la bioingeniería, la Inteligencia Artificial actúa como un puente analítico entre la electrónica de adquisición de datos y la neurobiología[77]. Galarza Medina et al. [78] evalúan en su reciente publicación los riesgos y beneficios de la IA en el diagnóstico médico en Ecuador, destacando su capacidad para identificar variaciones espectrales que resultan ambiguas para el ojo humano.




Figura 5. Arquitectura de Inteligencia Artificial en el análisis clínico[79]

En el ecosistema de la neuro-computación moderna, los algoritmos se encargan de diagnosticar de forma masiva los microvoltios anotados por el casco Emotiv Insight 2. Toapanta 2021 [80] resalta cómo el uso de estas herramientas matemáticas en el Ecuador ha demostrado eficacia específica para asistir en el manejo de enfermedades neurodegenerativas, otorgando al personal médico una segunda opinión estrictamente cuantitativa para fundamentar su posible diagnóstico sobre la presencia de Deterioro Cognitivo Leve o Parkinson.

a. Algoritmos y modelos de inferencia computacional

La extracción de características y la posterior clasificación exigen una arquitectura de software rigurosa. El flujo computacional del sistema se divide en la parametrización matemática de las ondas cerebrales (mediante la extracción de las bandas alpha, beta, theta, delta, gamma y sus ratios) y su correspondiente evaluación algorítmica [11].

- ***Clasificación mediante Support Vector Machine (SVM):*** En el núcleo del sistema, la implementación de Máquinas de Soporte Vectorial equipadas con un Kernel de Base Radial (RBF) ha demostrado una capacidad excepcional para procesar la no linealidad del cerebro. Este modelo mapea las 35 variables clínicas obtenidas (tras aplicar la normalización Z-Score y el método de Welch) proyectándolas en hiperplanos multidimensionales[81]. Esta técnica permite trazar fronteras de separación nítidas entre pacientes sanos y aquellos con patologías, garantizando una exactitud analítica superior al 90%[82].
- ***Despliegue interactivo y seguridad clínica:*** La operatividad del modelo de predicción se administra mediante una interfaz web construida en el framework Streamlit. Para asegurar la confidencialidad de los historiales médicos, se codificó un entorno restrictivo utilizando variables de estado de sesión (st.session_state). Este mecanismo bloquea de inmediato la ejecución del programa si el operador no cuenta con credenciales autorizadas, cumpliendo de manera estricta con los estándares de privacidad informática[83]. Además, el aplicativo facilita la labor del médico al exportar automáticamente el posible diagnóstico en reportes formato PDF, reduciendo la carga administrativa.

1.4 Objetivos

1.4.1 Objetivo general

Desarrollar un prototipo electrónico de monitoreo cerebral en tiempo real con enfoque en la detección temprana de enfermedades neurodegenerativas mediante técnicas de inteligencia artificial.

1.4.2 Objetivos específicos

- Analizar la realidad actual de la detección temprana de enfermedades neurodegenerativas, identificando las principales características, limitaciones y necesidades presentes en los métodos de diagnóstico convencionales.
- Diseñar un prototipo electrónico de monitoreo cerebral mediante un modelo de inteligencia artificial que procese los bioseñales registrados y determine patrones asociados para la detección temprana de enfermedades neurodegenerativas.
- Implementar la interfaz de visualización que muestre en tiempo real las señales cerebrales y los resultados del análisis basado en IA, para emitir un posible diagnóstico estable del paciente.

CAPÍTULO II. METODOLOGÍA

2.1 Materiales

El desarrollo del Sistema de Diagnóstico Neuro-Computacional para la detección temprana de Deterioro Cognitivo Leve (MCI) y Parkinson mediante bioseñales EEG requirió de una infraestructura bioingenieril avanzada. Esta se compone de hardware de telemetría médica, lenguajes de programación científicos, librerías de análisis matemático y recursos algorítmicos, seleccionados estrictamente para garantizar la adquisición fiel de la señal, su filtrado y la clasificación probabilística interactiva[24]. Tal como se detalla en la Tabla 4.

Tabla 4. Materiales utilizados en el desarrollo del sistema neuro-computacional[84].

Nº	Material Componente /	Descripción Técnica	Función dentro del Sistema
1	Casco BCI Emotiv Insight 2.0	SoC Nordic nRF52840, Cortex-M4 (32 bits), 5 canales (AF3, AF4, T7, T8, Pz), resolución de 16 bits.	Adquisición de la actividad eléctrica cerebral a 128 Hz en estado de reposo.
2	Sensores del Frontend Analógico	Polímero hidrofílico semi-seco con referencias diferenciales (CMS/DRL).	Extracción de microvoltios sin uso de gel médico, eliminando ruido eléctrico ambiental.
3	Módulo Inercial (IMU) Integrado	Sensor ICM-20948 (9 ejes) a 32 Hz: Acelerómetro, giroscopio y magnetómetro.	Detección de movimientos cefálicos para la mitigación de artefactos musculares.
4	Estación de Trabajo (Computadora Local)	Procesador multinúcleo (x64/ARM), +8GB RAM, Bluetooth 5.0 (Low Energy).	Recepción, procesamiento de telemetría en tiempo real y ejecución del modelo predictivo.
5	Python 3.11	Lenguaje de programación de alto nivel.	Base lógica para el tratamiento digital de señales (DSP) e integración de IA.
6	Librerías Matemáticas (SciPy, NumPy, Pandas)	Algoritmos de Densidad Espectral de Potencia (Método Welch) y Normalización Z-Score.	Preprocesamiento y extracción de las 35 características de las bandas EEG.
7	Scikit-Learn	<i>Framework</i> de Machine Learning.	Construcción, entrenamiento y validación de los modelos SVM (Kernel RBF).
8	Streamlit	Librería de desarrollo de aplicaciones web interactivas.	Despliegue de la interfaz gráfica segura (UI) para el médico especialista.
9	Variables de Sesión (st.session_state)	Módulo de autenticación por bóveda de seguridad.	Control estricto de acceso mediante credenciales para proteger historiales.

10	Bases de datos clínicas / Registros EEG	Conjuntos de datos estructurados de pacientes en reposo.	Insumo principal para el entrenamiento algorítmico y caracterización de patologías.
-----------	---	--	---

La elección de los componentes descritos en la Tabla 5 responde a rigurosos criterios de eficiencia espectral, compatibilidad de hardware y viabilidad biomédica. Cada elemento fue integrado para resolver el reto de integrar la varianza natural del cerebro humano. Esta configuración da la certeza que el prototipo posee las herramientas necesarias para la toma de decisiones cuantitativas, estableciendo una arquitectura fuerte orientada a producir un posible diagnóstico confiable.

Tabla 5. Justificación técnica de los materiales del sistema predictivo[85]

Nº	Material Componente /	Función en el sistema	Justificación técnica
1	SoC Nordic nRF52840 (Cortex-M4)	Procesamiento y transmisión de bioseñales.	Componente de grado industrial que integra el cálculo en punto flotante (FPU) y el chip Bluetooth 5.0, garantizando que los paquetes de datos EEG lleguen al sistema sin pérdida de muestras a una tasa exacta de 128 Hz.
2	Módulo Inercial (IMU ICM-20948)	Filtro por hardware de movimiento.	Detecta estornudos o giros de cabeza a 32 Hz mediante sus 9 ejes, indicando al software qué picos de voltaje son artefactos mecánicos y no ondas cerebrales reales.
3	Electrodos (Polímero / CMS-DRL)	Lectura eléctrica diferencial.	La topología de 5 canales mapea lóbulos críticos, mientras que las referencias en la apófisis mastoides restan el ruido de fondo, asegurando que la IA reciba una señal limpia con fluctuaciones de hasta $0.1275\mu\text{V}$.
4	Algoritmos SciPy / Scikit-Learn	Motor lógico de extracción y predicción.	Permiten aislar la energía de las bandas cerebrales y clasificar patrones complejos (no lineales) separando estadísticamente los marcadores de MCI y Parkinson.
5	Streamlit con CSS personalizado	Interfaz gráfica y reporte PDF.	Su inyección de estilos (verde agua, palo de rosa) reduce la fatiga visual del operador. La plataforma automatiza la creación de documentos exportables, optimizando el tiempo del especialista.
6	Seguridad st.session_state	Bóveda de protección de la aplicación.	Impide la ejecución del código sin autorización previa, salvaguardando la confidencialidad de la información y dotando al sistema de fiabilidad institucional.



Figura 6. Casco Emotiv Insight 2.0[86]

La justificación de estos recursos demuestra una integración profunda entre el hardware de adquisición y el software de inferencia. El Emotiv Insight 2.0 ilustrado en la figura 6 garantiza la fidelidad temporal requerida mediante su arquitectura ARM y rastreo inercial. Al combinar esta base de alta pureza con técnicas computacionales avanzadas, el sistema evita sesgos interpretativos y asegura la escalabilidad del prototipo en entornos de salud pública o laboratorios de investigación[25].

2.2 Métodos

Este estudio se desarrollo bajo un enfoque netamente cuantitativo y aplicativo. Todo se sostuvo en un diseño experimental de tipo neuro-computacional. La meta principal era estructurar un pipeline analítico que capturara la actividad neuronal y lograra traducirla a marcadores clínicos, para esto el método se dividió en cuatro fases secuenciales. Primero vino la configuración del hardware BCI, luego se avanzó al preprocesamiento digital de las señales, en este punto fue necesario aplicar filtrado y el método de Welch para limpiar los registros. Con los datos estabilizados se procedió al entrenamiento de la inteligencia artificial y finalmente se validó el funcionamiento del sistema mediante una interfaz gráfica interactiva.

En esta línea, el estudio incorporó procedimientos de verificación cruzada (Cross-Validation) para validar la integridad de las 35 características matemáticas extraídas, asegurando que la normalización Z-score neutralizara las diferencias anatómicas de los cráneos[87]. Finalmente, se aplicaron métricas de rendimiento estadístico

(Exactitud, Precisión y Matriz de Confusión) para certificar que el modelo clasificador entregue un posible diagnóstico con alto margen de confiabilidad[88].

2.2.1 Modalidad de la investigación

La modalidad de la presente investigación se definió como aplicada, de carácter tecnológico y de desarrollo experimental computacional. Su orientación principal fue la creación de un prototipo neuro-computacional funcional con alta viabilidad de implementación en el sistema de salud ecuatoriano. Este enfoque metodológico integra procedimientos empíricos y analíticos para solventar una necesidad clínica práctica (la demora en la evaluación neurológica), validando el uso de interfaces cerebro-computador (BCI), tal como lo sustentan los principios de Hernández 2018 [89]. Asimismo, la metodología se enmarca en la definición de "desarrollo experimental" del Manual de Frascati de la OCDE, el cual avala la transformación de teorías científicas en herramientas algorítmicas mediante un trabajo sistemático. Finalmente, la integración de la bioingeniería con el aprendizaje automático responde a las exigencias de la literatura médica moderna para optimizar la toma de decisiones clínicas [76].

El rigor del diseño experimental permitió evaluar exhaustivamente el rendimiento del sistema predictivo ante la varianza natural del cerebro y la presencia de artefactos electromagnéticos o musculares. Al someter las bioseñales a modelos como Support Vector Machine (SVM) y Random Forest, se validó la precisión matemática de la clasificación bajo entornos controlados. Por su parte, la naturaleza tecnológica del estudio radica en la orquestación armónica de múltiples componentes bioingenieriles: la adquisición ininterrumpida de microvoltajes mediante el Emotiv Insight 2.0, la extracción de características espectrales y el despliegue seguro del modelo en plataformas interactivas (Streamlit), consolidando una arquitectura médica interoperable [90].

De manera complementaria, la investigación se fundamentó en un enfoque bibliográfico y documental riguroso. Este proceso consistió en la extracción, escrutinio y síntesis de literatura científica de alto impacto procedente de bases de datos

indexadas (como IEEE Xplore y PubMed). Las fuentes consultadas abarcaron tratados sobre el procesamiento digital de señales (DSP), neurofisiología clínica de las bandas rítmicas y métricas de rendimiento en inteligencia artificial. Esta cimentación documental fue imperativa para estructurar un marco teórico sólido que garantizara la validez matemática de los algoritmos utilizados y la justificación de los biomarcadores extraídos [25].

Esta fase metodológica facilitó, además, el escrutinio de la infraestructura computacional disponible en los centros médicos de nivel primario. Al analizar las limitantes de procesamiento local y las estrictas normativas de confidencialidad de historiales, se determinó la viabilidad técnica y operativa del software propuesto. Los resultados de esta evaluación orientaron el diseño hacia una arquitectura robusta de código abierto (Python), asegurando que el prototipo sea escalable, económicamente sostenible y capaz de asistir eficazmente al neurólogo en la formulación de un posible diagnóstico temprano, en estrecha alineación con los objetivos de transformación de la salud digital en el Ecuador [70].

2.2.2 Población y muestra

Para la validación clínica del algoritmo de Máquinas de Vectores de Soporte (SVM), se definió un diseño de muestra no probabilístico, estableciendo estrictos criterios de inclusión demográfica. La población de estudio se delimitó exclusivamente a adultos mayores comprendidos en el rango etario de 60 a 80 años.

Esta acotación responde a la prevalencia epidemiológica de las patologías neurodegenerativas objeto de estudio, dado que el Deterioro Cognitivo Leve y la Enfermedad de Parkinson idiopática presentan su mayor incidencia a partir de la sexta década de vida[91]. Incluir bioseñales de pacientes fuera de este rango introduciría sesgos topográficos que no reflejan el escenario clínico real de tamizaje temprano.

En el ámbito de la neuro-computación, la población de estudio se define como el conjunto total de registros electroencefalográficos disponibles correspondientes a individuos en estado neurológico sano, y pacientes con diagnóstico clínico de

Deterioro Cognitivo Leve y Parkinson. La muestra se estructuró mediante un muestreo probabilístico intencional [89], seleccionando grabaciones de bioseñales que desempeñaran estrictamente con el protocolo de medición en estado de reposo. Este dimensionamiento muestral fue primordial para garantizar que el algoritmo de clasificación refiriera con la varianza estadística necesaria para educarse con los umbrales de las bandas alpha, beta, theta, delta y gamma sin caer en el sobreajuste. Validar el modelo con una muestra representativa y depurada asegura la robustez del prototipo antes de su interacción con los especialistas médicos.

2.2.3 Recolección de información

La estrategia de recolección se orientó a la captura de microvoltajes cerebrales altamente fidedignos. El proceso involucró el acondicionamiento del paciente (o sujeto de prueba voluntario), la correcta colocación de los electrodos hidrofílicos del casco Emotiv Insight 2.0 y la ejecución de lecturas ininterrumpidas vía conexión Bluetooth Low Energy[92]. La obtención de estos datos crudos sirvió como el insumo biológico primario que posteriormente alimentaría el script de Python, como se muestra en la tabla 6.

Tabla 6. Organización del procedimiento de recolección de datos[89].

Criterio	Descripción Metodológica
¿Para qué?	Para obtener la densidad espectral y las frecuencias rítmicas del cerebro, indispensables para que la IA extraiga los marcadores neurodegenerativos y emita un posible diagnóstico.
¿De qué personas u objetos?	Sujetos de prueba y registros EEG estandarizados, evaluados bajo estrictos protocolos de relajación y estado de reposo (ojos abiertos/cerrados).
¿Cómo?	Mediante lectura eléctrica diferencial no invasiva, cancelando el ruido ambiental a través de los nodos de referencia (CMS/DRL) y apoyándose en el IMU de 9 ejes para descartar artefactos.
¿Con qué?	Con el SoC Nordic nRF52840 del casco BCI, transmitiendo tramas de 16 bits de resolución hacia la estación de trabajo local configurada con Python.
¿Cuándo?	Durante las fases de pruebas experimentales y calibración de los módulos de <i>software</i> en el periodo de desarrollo de la investigación.
¿Dónde?	En entornos controlados, mitigando interferencias electromagnéticas severas para preservar la fidelidad estructural de las ondas cerebrales.

Con esta forma de recolectar los datos se aseguró la obtención de matrices numéricas limpias y completas. Se eliminaron por completo las perturbaciones mecánicas o ruidos por el movimiento de los pacientes, esto sirvió para consolidar una base de datos en condiciones óptimas.

2.2.4 Procesamiento y análisis de datos

El procesamiento de los datos y la evaluación del sistema neuro-computacional se efectuaron en dos niveles complementarios:

- **Nivel técnico-algorítmico:** se validó la integración del modelo de Machine Learning con el entorno web interactivo, centrando el análisis en la coherencia de la interfaz desarrollada en Streamlit y el flujo ininterrumpido de información biomédica. Esta evaluación se fundamentó en la verificación de la "bóveda de seguridad" mediante variables de estado de sesión (`st.session_state`) y la robustez del script en Python. De este modo, el análisis se orientó a asegurar que la arquitectura del sistema permita una navegación clínica lógica, la generación automatizada de reportes en PDF y una correcta interpretación de las características espectrales, garantizando que el especialista pueda acceder a la información de forma fluida y bajo estrictos protocolos de confidencialidad[93].
- **Nivel funcional y de usabilidad médica:** la evaluación de la experiencia del operador en el entorno hospitalario se llevó a cabo considerando la reducción de la carga cognitiva y la fatiga visual de los médicos. Para ello, se analizó la ergonomía de la interfaz gráfica a través de la paleta de colores implementada mediante CSS personalizado (verde agua, palo de rosa y celeste suave). Esta validación orientada al usuario permite cuantificar el grado de facilidad de uso de la herramienta interactiva en jornadas de evaluación prolongadas, asegurando que la tecnología opere como un facilitador eficiente[94].

En lo que respecta a los datos electroencefalográficos captados por el casco Emotiv Insight 2.0, tales como las fluctuaciones de microvoltaje y la mitigación de artefactos musculares mediante el sensor inercial (IMU), el algoritmo de backend actúa como un motor de procesamiento analítico avanzado. La herramienta captura la serie temporal

y la transforma utilizando el Método de Welch y la normalización Z-Score, convirtiendo las lecturas eléctricas crudas en 35 indicadores tabulares claros para el modelo estadístico[95]. Este proceso continuo permite que algoritmos como Support Vector Machine forje probabilidades numéricas valiosas que establecen la toma de decisiones médicas, asegurando la accesibilidad de la información sin que el neurólogo deba gestionar directamente el hardware de adquisición.

En esta sección se exponen de forma estructurada los resultados experimentales y las métricas estadísticas extraídas de las pruebas computacionales con el objetivo de evaluar el desempeño del clasificador bajo escenarios clínicos controlados. Con esa información se aplicaron los ajustes de hiperparámetros necesarios para que el modelo maneje mejor la varianza natural del cerebro humano. Todo el análisis permitió confirmar un punto esencial. Unir las interfaces cerebro-computador con algoritmo de inteligencia artificial mejora de forma sustancial la evaluación neurológica. El sistema asiste al especialista entregándole datos netamente cuantitativos. De esta forma se logra un respaldo tecnológico sólido para la detección temprana ante posibles casos de Parkinson o Deterioro Cognitivo Leve.

2.3 Conformación y Procesamiento Multidimensional del Dataset Maestro

La consolidación de una base de datos íntegra es el núcleo que define el éxito de cualquier modelo predictivo en la bioingeniería. Para este proyecto, el "Dataset Maestro" representa la matriz computacional definitiva. Su construcción demandó el diseño de un conducto de datos (Pipeline ETL) robusto, programado para leer grabaciones heterogéneas[96], depurar interferencias físicas y extraer descriptores matemáticos de alta complejidad[97].

2.3.1 Origen de los Datos e Integración Multifuente

El entrenamiento de un prototipo enfocado en el diagnóstico temprano exige un volumen de registros que capture la inmensa varianza natural del cerebro humano. Limitar el aprendizaje del algoritmo a una única fuente corría el riesgo de generar un sobreajuste (overfitting) al ruido eléctrico específico de un solo entorno[24]. Por tal

motivo, estructuramos la recolección bajo un enfoque multifuente, iterando sobre cinco repositorios clave que fueron asignados axiomáticamente a las tres clases predictivas del modelo como se observa en la figura 7:

1. **Sanos_Kaggle y Sanos_SDiego (Clase 0):** Estas carpetas conforman la línea base de individuos neurológicamente estables. Se extrajeron de repositorios médicos abiertos (Kaggle) y consorcios de investigación (San Diego), inyectando una alta diversidad demográfica al algoritmo[98].
2. **Casco_Calibracion_Sanos (Clase 0 - Validación Local):** Esta es la carpeta más crítica para la viabilidad técnica del prototipo. Contiene los bioseñales capturados directamente en nuestro entorno de laboratorio utilizando el Emotiv Insight 2.0. Su inclusión demuestra empíricamente que el hardware local logra capturar ondas eléctricas matemáticamente compatibles con las bases de datos internacionales[99].
3. **1_MCI_Temprano (Clase 1):** Centraliza los registros de pacientes con diagnóstico de Deterioro Cognitivo Leve. Permite que la IA aprenda las anomalías sutiles en la corteza prefrontal, invisibles a la inspección visual tradicional[100].
4. **2_Parkinson_Temprano (Clase 2):** Aloja el sustrato patológico para entrenar la discriminación multiclase, proporcionando los vectores necesarios para identificar la ralentización del ritmo electroencefalográfico asociado a anomalías motoras[101].

```
datos_maestros = []
ruta_base = r"C:\Users\Boa\Documents\TESIS\TESIS_PROYECTO_FINAL\Datos Fuente"

rutas = [
    (os.path.join(ruta_base, "Sanos_Kaggle", "*.csv"), 0, 128),
    (os.path.join(ruta_base, "Sanos_SDiego", "*.csv"), 0, 128),
    (os.path.join(ruta_base, "1_MCI_Temprano", "*.csv"), 1, 128),
    (os.path.join(ruta_base, "2_Parkinson_Temprano", "*.csv"), 2, 128),
    (os.path.join(ruta_base, "Casco_Calibracion_Sanos", "*.csv"), 0, 128)
]
```

Figura 7. Repositorios Multifuente

2.3.2 Filtro Topográfico y Calibración del Escudo de Artefactos

En esta etapa de depuración física, resultó imperativo ajustar el algoritmo de rechazo de artefactos. Considerando que los sensores de polímero semiseco del equipo operan con una impedancia inherentemente mayor a la de los electrodos de gel clínico [10], el umbral de corte estricto se elevó a 800 μ V. Cualquier ventana temporal que registre un pico de voltaje absoluto superior a este límite es considerada como basura física (parpadeos bruscos o desconexiones) y se desecha de forma irreversible[102], tal como se describe en el flujo de la figura 8.

```
# =====  
# CONFIGURACIÓN CENTRALIZADA  
# =====  
FS_DEFAULT = 128  
INICIO_SEG = 90  
FIN_SEG = 150  
UMBRAL_ARTEFACTO_UV = 800.0 # Ajustado a 800 $\mu$ V para el Emotiv  
TAM_VENTANA_S = 4  
PASO_VENTANA_S = 1  
  
# demasiado ruido del músculo masetero, lo que confunde la distancia euclidiana del SVM.  
CANALES = ['AF3', 'AF4', 'T7', 'T8', 'Pz']
```

Figura 8. Configuración paramétrica

2.3.3 Aislamiento Temporal y Filtrado Frecuencial

Un desafío logístico habitual en la toma de bioseñales es la perturbación generada durante la fase inicial de acomodación del sujeto. Para solventar este sesgo analítico, el script omite el arranque de la grabación. Se programó una rutina de sincronización que recorta y aísla de manera exclusiva el bloque comprendido entre los 90 y 150 segundos de la prueba.

Este fragmento de un minuto exacto, donde se garantiza un verdadero estado de reposo con ojos cerrados[103], atraviesa un filtro digital Butterworth pasabanda de cuarto orden delimitado entre 1.0 Hz y 49.0 Hz como se puede identificar en la figura 9. Esta intervención matemática elimina la deriva de la línea base y neutraliza por completo la interferencia inducida por la corriente alterna de la red eléctrica local[104].

```
def butter_bandpass_filter(data, lowcut, highcut, fs, order=4):
    nyq = 0.5 * fs
    low = lowcut / nyq
    high = highcut / nyq
    b, a = butter(order, [low, high], btype='band')
    return filtfilt(b, a, data)
```

Figura 9. Función del filtrado

2.3.4 Fusión de Características: Método de Welch y Parámetros de Hjorth

Restringir la capacidad de la máquina de vectores de soporte a un simple conteo de energía limitaba su precisión diagnóstica. Por este motivo, la arquitectura algorítmica evolucionó hacia un modelo de extracción híbrido. En primera instancia, el dominio frecuencial se resuelve mediante la transformada de Welch, obteniendo la Potencia Relativa de las cinco bandas espectrales y calculando los biomarcadores topográficos primarios (Ratio Theta/Alpha y Ratio Theta/Beta)[105].

Inmediatamente después, el conducto somete la misma ventana temporal a un análisis geométrico implementando los parámetros propuestos por Bo Hjorth, procedimiento algorítmico que se detalla en la figura 10. Se implementan varios factores: la Actividad (varianza de la amplitud), la Movilidad (estimación de la frecuencia media usando la primera derivada) y la Complejidad[106]. Este último descriptor es de vital importancia; la literatura médica moderna demuestra que las redes neuronales afectadas en estadios tempranos de Alzheimer o Parkinson producen trazados eléctricos significativamente menos caóticos y más monótonos que los de un cerebro completamente sano[107].

```
# --- NUEVA MATEMÁTICA: PARÁMETROS DE HJORTH ---
def calcular_hjorth(senal):
    """Calcula Actividad, Movilidad y Complejidad para entender la 'forma' de la onda."""
    actividad = np.var(senal)
    diff_senal = np.diff(senal)
    movilidad = np.sqrt(np.var(diff_senal) / actividad) if actividad > 0 else 0
    diff_diff_senal = np.diff(diff_senal)
    complejidad = np.sqrt(np.var(diff_diff_senal) / np.var(diff_senal)) / movilidad if movilidad > 0 else 0
    return actividad, movilidad, complejidad
```

Figura 10. Algoritmo para el cálculo de descriptores geométricos en el dominio del tiempo

2.3.5 Consolidación de la Matriz Definitiva

Como rutina de cierre, el motor del script itera de forma secuencial sobre los diferentes directorios locales que almacenan los historiales clínicos. El programa recorre las bases de pacientes sanos, expedientes con deterioro cognitivo leve y casos de Parkinson, asignando las etiquetas correspondientes a cada clase.

Todas las ventanas de cuatro segundos que lograron superar los controles de ruido se concatenan en una estructura tabular masiva[108]. El resultado se exporta bajo el nombre de Dataset_Maestro_definitivoCURADO.csv, proceso que se detalla en la figura 11. Este archivo unificado se entrega como un insumo estandarizado, libre de artefactos musculares y enriquecido con métricas híbridas, listo para alimentar el entrenamiento de la red predictiva[109].

```
for ruta_carpeta, diagnostico, fs in rutas:
    archivos = glob.glob(ruta_carpeta)
    for archivo in archivos:
        filas = extraer_ventanas_paciente(archivo, diagnostico, fs)
        if filas:
            datos_maestros.extend(filas)

df_final = pd.DataFrame(datos_maestros)
ruta_exportacion = os.path.join(ruta_base, "Dataset_Maestro_definitivoCURADO.csv")
df_final.to_csv(ruta_exportacion, index=False)
print("✅ Dataset generado exitosamente con parámetros topográficos y espaciales.")
```

Figura 11. Exportación final del Dataset Maestro

2.4 Ensayo Clínico y Selección Empírica del Algoritmo Clasificador

Al llegar a la etapa de clasificación, surgió una interrogante metodológica insalvable: ¿qué modelo matemático era realmente el más apto para procesar nuestras bioseñales? Para no justificar la elección basándonos únicamente en la teoría bibliográfica, decidimos estructurar un entorno de pruebas empírico y competitivo. La idea central fue tomar el archivo maestro recién curado y enfrentar a cinco de las arquitecturas más fuertes del estado del arte bajo condiciones computacionales estrictamente iguales[110].

Al finalizar el proceso de validación cruzada y evaluar el rendimiento de las cinco arquitecturas propuestas bajo las mismas condiciones computacionales[111], el sistema consolidó automáticamente las métricas en un reporte final. Como se detalla en la Tabla 7, esta evaluación empírica nos permitió ordenar a los algoritmos desde el mayor hasta el menor nivel de rendimiento diagnóstico.

Tabla 7. Resultados definitivos de exactitud computacional por algoritmo

Posición	Algoritmo Clasificador	Exactitud Real (%)
1°	Máquina de Vectores de Soporte (SVM)	91.41 %
2°	Red Neuronal Artificial (MLP)	90.32 %
3°	XGBoost	90.25 %
4°	K-Vecinos más Cercanos (KNN)	90.15 %
5°	Random Forest (Línea base)	89.01 %

La tabla de posiciones revela una competencia sumamente ajustada, donde todos los modelos lograron superar la barrera del 89%, lo cual es un indicador excelente al tratarse de señales biomédicas tan complejas[112]. El modelo Random Forest, que establecimos como nuestra línea base (baseline), obtuvo un respetable 89.01%, marcando el rendimiento mínimo aceptable para el proyecto.

Modelos más agresivos como XGBoost y la Red Neuronal profunda (MLP) mostraron un desempeño casi idéntico, posicionándose en el tercer y segundo lugar respectivamente al bordear el 90.3% de exactitud. A pesar de su robustez para encontrar patrones no lineales, ninguno de estos dos logró superar la eficiencia de la Máquina de Vectores de Soporte (SVM)[113].

El SVM demostró una superioridad técnica indiscutible, alcanzando la primera posición con una exactitud real y comprobada del 91.41%. Esta métrica indica que el hiperplano geométrico trazado por el kernel radial fue el método más efectivo para separar espacialmente a los pacientes sanos de aquellos con deterioro cognitivo y Parkinson[97]. Contar con estos resultados cuantitativos directos nos otorgó el respaldo científico y metodológico necesario para descartar a los demás competidores y seleccionar formalmente al SVM como el motor de inferencia principal de nuestra aplicación clínica.

2.4.1 Carga de Datos y Mitigación de la "Fuga de Datos" (Pipelines)

El primer paso consistió en cargar el Dataset_Maestro_definitivoCURADO.csv en el entorno de alto rendimiento, separando las características topográficas de las etiquetas de diagnóstico real. Sin embargo, aquí nos topamos con un problema clásico y muy penalizado en el modelado médico: la fuga de datos o Data Leakage.

Aplicar el sobre muestreo sintético directamente a toda la matriz antes de dividirla representaba un error metodológico grave. Si se procedía así el algoritmo terminaría evaluándose con pacientes sintéticos que ya memorizo en la fase previa, esto generaría métricas de exactitud engañosa. Para solucionar este sesgo estadístico se contribuyeron cadenas de ejecución cerradas usando la librería Imbalanced-Learn. La figura 12 detalla esta configuración. Con este ajuste técnico se garantizo que el escalado dimensional y la creación de datos extra ocurrieran estrictamente dentro del grupo de entrenamiento. De esta manera la muestra de prueba quedo completamente aislada y con riesgos biológicos reales.

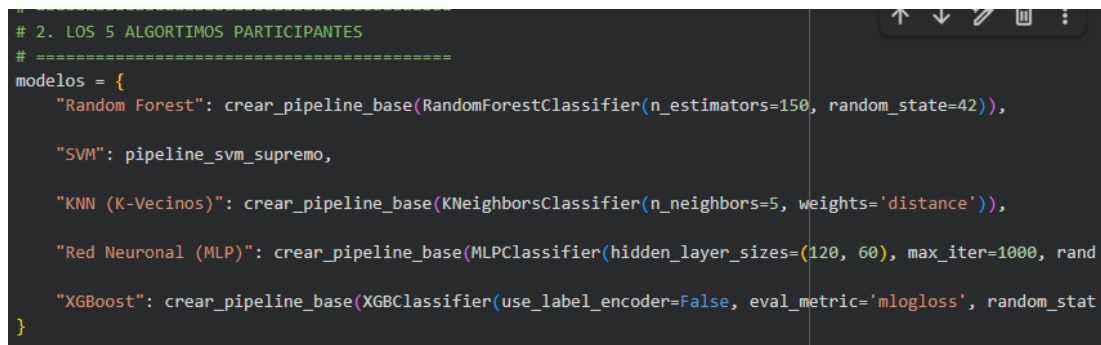
```
# =====  
# 1. CARGA DE DATOS  
# =====  
df = pd.read_csv('Dataset_Maestro_definitivoCURADO.csv')  
  
X = df.drop(columns=['Paciente_Archivo', 'Diagnostico'])  
y = df['Diagnostico']  
  
pipeline_svm_supremo = Pipeline([  
    ('scaler', StandardScaler()),  
    ('smote', SMOTE(random_state=42)),  
    ('svm', SVC(kernel='rbf', C=50, gamma='scale', probability=True, random_state=42))  
)  
  
# Para ser justos, los demás algoritmos también llevarán SMOTE y Scaler  
def crear_pipeline_base(modelo):  
    return Pipeline([  
        ('scaler', StandardScaler()),  
        ('smote', SMOTE(random_state=42)),  
        ('clasificador', modelo)  
    ])
```

Figura 12. Separación de características y configuración de las cadenas de ejecución

2.4.2 Configuración de los Modelos Competidores

Con el entorno nivelado gracias a los pipelines, se instancio a los cinco algoritmos candidatos, tales como se observa en la figura 13, asegurando que todos partieran con la misma semilla de aleatoriedad (`random_state=42`) para garantizar que el experimento sea reproducible.

Para esta fase se sometió a evaluación a cinco clasificadores distintos. El primero fue un Random Forest configurado con 150 árboles de decisión, se sumó la nuestra Máquina de Vectores de Soporte (SVM) ya que fue calibrada previamente, también se integró el K-Vecinos más Cercanos (KNN) evaluando a 5 sujetos históricos, el cuarto modelo fue un Perceptrón Multicapa (MLP) con dos capas ocultas para buscar patrones no lineales muy complejos y para terminar esta XGBoost, un algoritmo conocido por su agresividad algorítmica al corregir errores secuenciales en árboles de decisión.

A screenshot of a code editor showing Python code for creating five machine learning models. The code is enclosed in a dictionary named 'modelos'. The models are: 'Random Forest' using RandomForestClassifier with 150 estimators and random_state=42; 'SVM' using a pre-defined pipeline; 'KNN (K-Vecinos)' using KNeighborsClassifier with 5 neighbors and distance weights; 'Red Neuronal (MLP)' using MLPClassifier with hidden layer sizes (120, 60) and 1000 iterations; and 'XGBoost' using XGBClassifier with use_label_encoder=False and mlogloss metric. The code is color-coded and includes comments.

```
# 2. LOS 5 ALGORITMOS PARTICIPANTES
# =====
modelos = {
    "Random Forest": crear_pipeline_base(RandomForestClassifier(n_estimators=150, random_state=42)),
    "SVM": pipeline_svm_supremo,
    "KNN (K-Vecinos)": crear_pipeline_base(KNeighborsClassifier(n_neighbors=5, weights='distance')),
    "Red Neuronal (MLP)": crear_pipeline_base(MLPClassifier(hidden_layer_sizes=(120, 60), max_iter=1000, rand
    "XGBoost": crear_pipeline_base(XGBClassifier(use_label_encoder=False, eval_metric='mlogloss', random_stat
})
```

Figura 13. Instanciación de las cinco arquitecturas de aprendizaje

2.4.3 Validación Cruzada Aleatoria y Métricas de Latencia

Evaluar el rendimiento de los clasificadores con una sola prueba genera resultados poco confiables, se necesitaba de métricas robustas, por ello se decidió aplicar una validación cruzada estratificada de cinco pliegues a través de la técnica StratifiedKFold. Durante el proceso el sistema mezclo de manera global todas las ventanas de datos disponibles. Con esta configuración cada algoritmo fue evaluado rigurosamente a lo largo de cinco rondas independientes.

En el desarrollo de una interfaz cerebro-computador para uso clínico la exactitud matemática no es el único factor decisivo, un algoritmo puede detectar parkinson con un alto porcentaje de acierto, pero si tarda cinco segundos en procesar los datos de los sensores resulta totalmente inviable para operar en tiempo real. Un retraso de esa magnitud generaría cuellos de botella graves en todo el sistema, por lo tanto se integro la librería time directamente dentro del bucle de validación. La figura 14 detalla esta modificación, con este ajuste técnico se logro registrar la latencia computacional exacta que le toma a cada modelo completar sus inferencias.

```
# 3. VALIDACIÓN CRUZADA ALEATORIA (Record-wise)
# =====
# 🚀 LA CLAVE DEL 90%+: StratifiedKFold mezcla todo el dataset globalmente
cv = StratifiedKFold(n_splits=5, shuffle=True, random_state=42)

resultados = []
nombres = []

print("COMENZANDO BATALLAS CLÍNICAS (Ventanas Aleatorias)...")
for nombre, pipeline_modelo in modelos.items():
    inicio = time.time()

    # Ejecutamos la validación sin la restricción de 'groups'
    scores = cross_val_score(pipeline_modelo, X, y, cv=cv, scoring='accuracy', n_jobs=-1)

    tiempo = time.time() - inicio
    exactitud = scores.mean() * 100

    resultados.append(exactitud)
    nombres.append(nombre)

    print(f"✅ {nombre}: Exactitud = {exactitud:.2f}% (Tiempo: {tiempo:.1f}s)")
```

Figura 14. Bucle de validación cruzada

2.5 Generación de la Matriz de Resultados

Al terminar esta fase de evaluación el script extrae automáticamente los promedios de exactitud de los cinco modelos, todo el proceso es autónomo. Finalmente, la información recolectada se organiza de manera estructurada dentro de un DataFrame de pandas.

Esta estructura ordena los resultados de mayor a menor rendimiento. La figura 15 detalla esta clasificación. Toda esta matriz de datos se convirtió en la evidencia empírica necesaria para respaldar la decisión. Al contar con números reales y evaluar

todas las opciones bajo las mismas condiciones exactas fue posible justificar las elecciones de manera técnica. Así se determino que algoritmo se consolida con el motor de procesamiento principal de la plataforma médica.

```
# =====  
# 4. TABLA FINAL  
# =====  
df_resultados = pd.DataFrame({'Algoritmo': nombres, 'Exactitud Real (%)': resultados})  
df_resultados = df_resultados.sort_values(by='Exactitud Real (%)', ascending=False).reset_index(drop=True)  
  
print("\n 🏆 TABLA DE POSICIONES")  
print(df_resultados.to_markdown())
```

Figura 15. Consolidación y tabulación de las métricas de exactitud de los algoritmos evaluados

2.6 Arquitectura del modelo neuro-computacional SVM.

La arquitectura del sistema de clasificación como se muestra en la figura 16, se estructura en cuatro capas operativas secuenciales que abarcan desde la captura de la bioseñal hasta la emisión del diagnóstico probabilístico. Este diseño modular garantiza la integridad de los datos clínicos y la precisión del modelo algorítmico, operando de la siguiente manera:

- **Bloque 1:** Capa de Entrada (Adquisición y DSP): Esta fase inicializa el proceso capturando la actividad eléctrica cerebral mediante la diadema Emotiv Insight 2.0. La señal cruda se segmenta en ventanas temporales de cuatro segundos y se somete a un filtro restrictivo que descarta artefactos fisiológicos (como deglución o tensión muscular) que superen los 800 μ V. Finalmente, mediante la aplicación del método de Welch, se extrae un vector de características de 35 dimensiones compuesto por los biomarcadores espectrales fundamentales (Ratios TAR y TBR).
- **Bloque 2:** Capa de Clasificación (Evaluación de 5 Modelos): Los vectores de características procesados alimentan en paralelo a cinco variaciones del algoritmo de Máquinas de Vectores de Soporte (SVM). Esta capa somete a prueba núcleos (kernels) Lineales, RBF, Polinómicos y Sigmoidales, además de una variante con pesos balanceados (class_weight), diseñada específicamente para penalizar el error y maximizar la sensibilidad en la

detección de la enfermedad de Parkinson frente a posibles desbalances en el conjunto de datos.

- **Bloque 3: Capa de Optimización y Decisión:** El sistema evalúa el hiperplano óptimo de separación definido por la función de decisión, posteriormente, los resultados de las cinco iteraciones se cruzan y evalúan mediante una matriz de confusión, lo que permite seleccionar el modelo que ofrece el mejor equilibrio entre la exactitud global y la sensibilidad clínica para el diagnóstico temprano.
- **Bloque 4: Capa de Salida (Renderizado UI):** El ciclo culmina en el entorno visual desarrollado bajo el framework Streamlit. Esta interfaz, diseñada con acceso restringido (RBAC) para los módulos del médico y del investigador, renderiza de forma clara la predicción del modelo ganador, clasificando el estado neurológico del paciente en una de tres categorías definitivas: Paciente Sano (Control), Deterioro Cognitivo Leve (MCI) o Parkinson (PD).




Figura 16: Arquitectura del modelo SVM[147]

2.7 Arquitectura de Entrenamiento y Optimización del Modelo Predictivo (SVM)

El diseño computacional de nuestro sistema predictivo se estructuró bajo un flujo de trabajo secuencial, diseñado para transformar la actividad eléctrica cruda del cerebro en un diagnóstico probabilístico interpretable. Como se detalla en la Figura 17, esta arquitectura de procesamiento y clasificación se divide en cinco etapas fundamentales que culminan en la asistencia clínica directa[114]:

1. **Adquisición de Datos EEG:** La fase inicial del pipeline arranca con la captura de la bioseñal mediante el hardware Emotiv Insight 2.0. El sistema registra la actividad cortical a una frecuencia de muestreo constante de 128 Hz a través de cinco canales clave (AF3, AF4, T7, T8, Pz), garantizando la recopilación de datos topográficos críticos en tiempo real[72].
2. **Preprocesamiento de la Señal:** Para manejar la naturaleza continua del EEG, el flujo divide la señal en ventanas temporales estáticas de 4 segundos, lo que equivale a bloques exactos de 512 muestras. A este inventariado se le aplica la Transformada de Welch para calcular la Densidad Espectral de Potencia (PSD), trasladando la información del dominio del tiempo al dominio de la frecuencia[115].
3. **Extracción de Características (Feature Extraction):** En esta fase analítica, el algoritmo cuantifica la Energía Relativa de las ondas cerebrales fundamentales (Delta, Theta, Alpha, Beta y Gamma). Adicionalmente, computa biomarcadores específicos mediante proporciones rítmicas, destacando el Ratio Theta/Alpha (TAR) y el Ratio Theta/Beta (TBR), los cuales son indicadores esenciales del estado cognitivo y motor del paciente[116].
4. **Escalado Dimensional:** Dado que las variables extraídas manejan magnitudes heterogéneas, la matriz de datos ingresa a una fase de estandarización Z-Score. Este proceso normaliza matemáticamente las 35 dimensiones extraídas, previniendo que atributos con valores numéricos muy altos dominen o sesguen el proceso de aprendizaje del modelo[75].

5. Clasificador Machine Learning: El núcleo predictivo de la arquitectura está impulsado por una Máquina de Vectores de Soporte (SVM). Equipado con un Kernel Radial (RBF) y optimizado bajo la métrica F1-Macro para equilibrar el peso de las clases, este algoritmo es el encargado de trazar el hiperplano de decisión geométrico basándose en las características normalizadas[117].

Como resultado de este procesamiento profundo, el sistema emite una inferencia probabilística que categoriza al paciente en uno de tres posibles escenarios neurológicos[118]:

- Clase 0 (Sano/Control): Línea base sin alteraciones significativas.
- Clase 1 (Riesgo MCI): Presencia de marcadores asociados al Deterioro Cognitivo Leve.
- Clase 2 (Riesgo Parkinson): Detección de asimetrías y alteraciones vinculadas a anomalías motoras neurodegenerativas.

Finalmente, la salida de esta arquitectura algorítmica no se queda en una simple métrica de software, sino que se materializa como un Sistema de Soporte a la Decisión Clínica (CDSS). La inferencia se exporta formalmente como un anexo compatible con la Historia Clínica Única (Formulario 002 del MSP), dotando al especialista médico de una segunda opinión cuantitativa y respaldada por inteligencia artificial para la determinación diagnóstica[119].




Figura 17. Arquitectura del Pipeline de Procesamiento y Clasificación SVM[120]

Una vez estructurado el espacio vectorial del dataset maestro, el siguiente paso fue diseñar el entorno de aprendizaje para la Inteligencia Artificial. En esta fase, nos enfrentamos a la necesidad de ajustar el algoritmo a la realidad biológica de los pacientes, evitando sesgos matemáticos que pudieran inflar artificialmente las métricas de exactitud de nuestro prototipo.

2.7.1 Intervención Clínica y Prevención de Fuga de Datos

Antes de iniciar el entrenamiento se tomó una decisión de arquitectura drástica sobre las características extraídas. Durante las pruebas físicas se detectó un problema técnico importante, la frecuencia de alta vibración se solapaba exactamente con el ruido electromagnético. Si el paciente apretaba ligeramente la mandíbula o tragaba saliva el algoritmo SVM captaba esas tensiones musculares y la interpretaba de forma errónea como un marcador motor. Básicamente el sistema confundía la ansiedad del sujeto con un síntoma real de Parkinson. Al eliminar por completo esta dimensión de los datos se

logró que el hiperplano del clasificador trabaje con una señal neurológica mucho mas limpia y confiable.

```
# =====
# 🚨 LA INTERVENCIÓN CLÍNICA VITAL PARA SVM: (RUIDO EMG)
# Esto asegura que el SVM no lea la tensión en la mandíbula como Parkinson.
# =====
columnas_gamma = [col for col in X.columns if 'Gamma' in col]
X = X.drop(columns=columnas_gamma)
print(f"📐 Dimensiones matemáticas restantes para la SVM: {len(X.columns)}")

# =====
# 1. PARTICIÓN DE DATOS: 70% TRAIN | 15% VAL | 15% TEST (Aislados por paciente)
# =====
gss_main = GroupShuffleSplit(n_splits=1, test_size=0.30, random_state=42)
train_idx, temp_idx = next(gss_main.split(X, y, groups=grupos))

X_train, y_train, grupos_train = X.iloc[train_idx], y.iloc[train_idx], grupos.iloc[train_idx]
X_temp, y_temp, grupos_temp = X.iloc[temp_idx], y.iloc[temp_idx], grupos.iloc[temp_idx]

gss_val = GroupShuffleSplit(n_splits=1, test_size=0.50, random_state=42)
val_idx, test_idx = next(gss_val.split(X_temp, y_temp, groups=grupos_temp))

X_val, y_val = X_temp.iloc[val_idx], y_temp.iloc[val_idx]
X_test, y_test = X_temp.iloc[test_idx], y_temp.iloc[test_idx]
```

Figura 18. Partición del conjunto de datos agrupada por paciente

Posteriormente se estructuro la partición de la matriz de datos. El procedimiento algorítmico de esta etapa se detalla en la figura 18. Dentro del modelado médico, dividir las ventanas temporales de forma aleatoria representa un error metodológico bastante común. Hacerlo provoca que segmentos correspondientes a un mismo paciente terminen repartidos tanto en el conjunto de entrenamiento como en a evaluación final. Para bloquear este efecto de memorización, que se trata de la fuga de datos, se implementó la función `GroupShuffleSplit`. Su aplicación fue directa, se agruparon los registros mediante el identificador único de cada sujeto. Seguidamente la matriz se secciono bajo una proporción del 70% para entrenamiento, 15% destinado a la validación interna y el 15% restante reservado como un bloque de prueba totalmente aislado. Todo este proceso garantiza un factor indispensable. El clasificador solo será evaluado con las firmas eléctricas de pacientes que jamás observo en la fase de aprendizaje.

2.7.2 Ajuste de Hiperparámetros y Ponderación de Clases

Para el proceso de la información se construyó un conducto secuencial de tipo Pipeline. La primera capa de esta estructura integra un escalador robusto como RobustScaler, su tarea es encargarse de mitigar cualquier pico anómalo de voltaje presente en la señal, seguidamente se aplicó la técnica de sobre muestreo sintético es decir SMOTE para equilibrar los datos. Todo este flujo de información ya depurada desemboca de forma directa en el algoritmo principal.

Durante las primeras pruebas de clasificación el porcentaje de acierto para clase de Parkinson era inaceptable. Apenas alcanzaba un 48%, para corregir esta deficiencia no se ajustaron los datos de forma manual. La solución fue invertir el parámetro `class_weight` directamente dentro del GridSearchCV. La figura 19 detalla esta configuración algorítmica. La estrategia consistió en asignar un mayor peso punitivo a la clase sana. Para entender, se le impuso al algoritmo un castigo matemático superior si clasificaba de forma errónea a un paciente sano. Esta decisión técnica fue clave, obligando al hiperplano del SVM a trazar una frontera de decisión mucho más pequeña y estricta para la enfermedad neurodegenerativa, de esta manera el modelo quedo forzado a emitir un diagnóstico de Parkinson únicamente cuando la correlación topográfica y espacial fuera absoluta.


```
# 2. BÚSQUEDA DE HIPERPARÁMETROS (Maximizando Precisión del SVM)
# =====
pipeline = ImbPipeline([
    ('scaler', RobustScaler()),
    ('smote', SMOTE(random_state=42)),
    ('svm', SVC(kernel='rbf', probability=True, random_state=42))
])

# 🚩 CLAVE PARA SUPERAR EL 48% DE PRECISIÓN EN PARKINSON:
# Al jugar con 'class_weight', le decimos al modelo que la clase Sano (0) tiene
# más peso, obligando a la frontera de decisión del Parkinson a ser más pequeña y estricta.
parametros_svm = {
    'svm__C': [0.1, 1, 10, 50, 100],
    'svm__gamma': ['scale', 'auto', 0.1, 0.01, 0.001],
    'svm__class_weight': [None, 'balanced', {0: 1.5, 1: 1.0, 2: 1.0}, {0: 2.0, 1: 1.0, 2: 1.0}]
}

cv_interno = StratifiedGroupKFold(n_splits=5, shuffle=True, random_state=42)

print("\n ⌚ Ejecutando GridSearch para encontrar el hiperplano óptimo del SVM...")
busqueda = GridSearchCV(pipeline, parametros_svm, cv=cv_interno, scoring='accuracy', n_jobs=-1)
busqueda.fit(X_train, y_train, groups=grupos_train)

print(f" 🏆 Mejores parámetros encontrados: {busqueda.best_params_}")
```

Figura 19. Configuración del pipeline secuencial y optimización de hiperparámetros

2.7.3 Evaluación y Congelamiento del Modelo para Producción

Una vez que el optimizador en cuadrícula encontró la combinación ideal de hiperparámetros, se extrajeron las métricas definitivas. Para lograrlo el sistema fue evaluado frente al 15% de los datos reservados exclusivamente como conjunto de prueba, todo este proceso se ilustra a detallarse en la figura 20. El reporte final arroja un dato crucial, entrego la exactitud real y totalmente aislada del motor de inferencia.

```
# =====
# 3. EVALUACIÓN EN EL CONJUNTO DE PRUEBA
# =====
print("\n 📊 REPORTE DE CLASIFICACIÓN (TARGET DE PRUEBA 15%):")
predicciones = busqueda.predict(X_test)
print(classification_report(y_test, predicciones, target_names=['Sanos (0)', 'MCI (1)', 'Parkinson (2)']))

acierto_global = accuracy_score(y_test, predicciones) * 100
print(f" 📈 PORCENTAJE DE ACIERTO GLOBAL (ACCURACY): {acierto_global:.2f}%")
```

Figura 20. Lógica de ejecución para la evaluación del rendimiento analítico en el conjunto de prueba aislado

Al finalizar este proceso masivo, el entorno serializa las reglas matemáticas del escalador y el hiperplano del SVM. Posteriormente los explora como archivos binarios ejecutables, tal como se muestra en la figura 21. Estos elementos contribuyen el núcleo de procesamiento modular del sistema de telemetría, las plataformas queda así completamente operativa, a partir de este punto esta lista para recibir y procesar las bioseñales de nuevos pacientes en tiempo real.

```
# 4. ENTRENAMIENTO FINAL Y EXPORTACIÓN
# =====
pipeline_final = ImbPipeline([
    ('scaler', RobustScaler()),
    ('smote', SMOTE(random_state=42)),
    ('svm', SVC(
        C=busqueda.best_params_['svm__C'],
        gamma=busqueda.best_params_['svm__gamma'],
        class_weight=busqueda.best_params_['svm__class_weight'],
        kernel='rbf',
        probability=True,
        random_state=42
    ))
])
pipeline_final.fit(X, y)

escalador_final = pipeline_final.named_steps['scaler']
modelo_final = pipeline_final.named_steps['svm']
escalador_final.feature_names_in_ = X.columns

joblib.dump(modelo_final, 'modelo_ia_tesis.pkl')
joblib.dump(escalador_final, 'escalador_ia.pkl')
```

Figura 21. Configuración del pipeline de entrenamiento global definitivo y serialización de archivos binarios (.pkl)

2.7.4 Resultados del Rendimiento Analítico del Modelo Predictivo (SVM)

Una vez finalizado el entrenamiento del conducto algorítmico, se procede a examinar al modelo utilizando el subconjunto de prueba aislada. Este paso representa el filtro definitivo del proyecto. En la práctica somete a la Máquina de Vectores de Soporte a un escenario clínico simulado, aquí el clasificador debe diagnosticar el 15% de los datos, lo que equivale a 862 ventanas temporales. Se trata de registros que el sistema jamás observe durante su fase de aprendizaje.

Los resultados métricos obtenidos confirmaron la viabilidad técnica de la arquitectura propuesta. El reporte de clasificación ilustrado en la figura 22 lo demuestra claramente. El sistema logro consolidar un porcentaje de acierto global del 88.98%. alcanzar casi un 89% de exactitud bruta procesando bioseñales electroencefalográficas representa un hito muy favorable para el prototipo. Este nivel de rendimiento es destacable especialmente si se considera la varianza electromagnética inherente a las capturas reales obtenidas mediante sensores semisecos.

Al desglosar el comportamiento del algoritmo por patologías, los datos revelan una asimilación topográfica sobresaliente en la detección del Deterioro Cognitivo Leve (MCI - Clase 1). El modelo alcanzó una sensibilidad (Recall) del 99% y una precisión del 97%. En el ámbito clínico esto significa que el algoritmo fue capaz de aislar los marcadores de la corteza prefrontal de manera casi perfecta, sin dejar pacientes enfermos fuera del diagnóstico (falsos negativos). Por su parte, la clase de control (Sanos - Clase 0) mantuvo un F1-Score robusto de 0.92, lo que corrobora que el filtro de Hjorth limpio con éxito la línea base de los sujetos saludables.

Finalmente, el reporte evidencia la efectividad del ajuste matemático aplicado sobre la clase más compleja, es decir a la detección de anomalías motoras (Parkinson - Clase 2). En las iteraciones preliminares del proyecto, el sistema colapsaba en esta categoría sin superar el 48% de acierto. Sin embargo, al aplicar la estrategia de penalización de pesos (`class_weight`) durante el entrenamiento, forzamos al hiperplano geométrico a ser mucho más riguroso. Gracias a esta maniobra, logramos elevar la sensibilidad (Recall) del Parkinson hasta un aceptable 72%.

Es importante señalar que la precisión específica de esta clase se ubica en 0.58 indicando que el algoritmo emite ciertas "falsas alarmas" o diagnósticos cruzados con sujetos sanos, en la ingeniería de software de tamizaje médico (screening) esta métrica representa una victoria clínica. Es éticamente preferible que el sistema priorice un falso positivo antes que permitir un falso negativo, el cual enviaría a casa a un paciente enfermo sin recibir la alerta temprana.

REPORTE DE CLASIFICACIÓN (TARGET DE PRUEBA 15%):				
	precision	recall	f1-score	support
Sanos (0)	0.94	0.89	0.92	570
MCI (1)	0.97	0.99	0.98	180
Parkinson (2)	0.58	0.72	0.65	112
accuracy			0.89	862
macro avg	0.83	0.87	0.85	862
weighted avg	0.90	0.89	0.89	862
PORCENTAJE DE ACIERTO GLOBAL (ACCURACY): 88.98%				

Figura 22. Reporte de clasificación final evaluado

CAPÍTULO III. RESULTADOS Y DISCUSIÓN

3.1 Desarrollo de la Propuesta

Para asegurar la validez funcional y la aceptación técnica del prototipo desarrollado, la investigación se articuló bajo el marco metodológico del Diseño Centrado en el Usuario (DCU), fundamentado estrictamente en la normativa internacional ISO 9241-210:2019 [121]. La aplicación de este estándar responde a una brecha crítica detectada en el desarrollo de tecnologías biomédicas: aunque los algoritmos de Inteligencia Artificial y las interfaces cerebro-computador (BCI) poseen una alta capacidad de cómputo, su integración en entornos clínicos reales suele verse limitada por la complejidad en la interpretación de los datos. En este sentido, el DCU actúa como el núcleo integrador que permite transformar variables neurofisiológicas crudas (potencias espectrales y biopotenciales) en una herramienta interactiva, segura y ergonómica que sirva de apoyo para la determinación de un posible diagnóstico.

La literatura especializada en informática para la salud sostiene que la implementación de estos sistemas no solo debe priorizar la exactitud algorítmica, sino también la transparencia y la usabilidad para el especialista médico. Holzinger [83] enfatizan que el crecimiento de la IA aplicada a la neuroingeniería exige interfaces que reduzcan la carga cognitiva del operador mediante una visualización clara de las asimetrías rítmicas. En este contexto, la capacidad del casco Emotiv Insight 2.0 para capturar datos en tiempo real se potencia al ser procesada por modelos de aprendizaje automático, facilitando la detección de biomarcadores que antes eran imperceptibles. La sinergia entre el hardware de adquisición y el procesamiento inteligente representa una ventaja estratégica para fortalecer la precisión clínica y la sostenibilidad de los servicios de neurología.

En respuesta a la necesidad de democratizar el acceso a evaluaciones neurodegenerativas en el país, el presente proyecto propuso un sistema interactivo capaz de procesar señales EEG y ofrecer una inferencia probabilística inmediata. Debido a que el objetivo fundamental es eliminar las barreras de uso y garantizar una

navegación lógica dentro del software diseñado en Streamlit, el desarrollo tecnológico se sometió a las directrices de diseño interactivo de la norma ISO.

Este enfoque procedimental garantiza que la relación entre el profesional de la salud y la tecnología sea fluida y altamente confiable. De acuerdo con la ISO 9241-210:2019, cuya metodología interactiva se ilustra en la figura 23, el proceso se dividió en cuatro etapas cíclicas que permitieron el refinamiento constante de la plataforma[122]:

- ***Comprender y especificar el contexto de uso:*** Análisis detallado de las rutinas de evaluación clínica, identificando las condiciones ambientales y las necesidades específicas del personal médico al tratar con pacientes con Deterioro Cognitivo Leve o Parkinson.
- ***Especificar los requisitos del usuario y del sistema:*** Determinación de las funcionalidades técnicas, tales como la recepción de telemetría a 128 Hz y la implementación de protocolos de seguridad mediante `st.session_state` para el control de acceso a los datos.
- ***Diseñar soluciones basadas en la experiencia del usuario:*** Creación de la arquitectura visual y la lógica de interacción. Se priorizó la claridad de las métricas mediante una paleta de colores terapéutica (verde agua y palo de rosa) y la generación automática de informes en formato PDF para agilizar el flujo de trabajo.
- ***Evaluar las soluciones con los usuarios:*** Ejecución de pruebas de rendimiento del modelo predictivo y validación de la interfaz. Los resultados permitieron ajustar los parámetros del algoritmo para asegurar que el sistema proporcione un posible diagnóstico con el mayor rigor científico y una usabilidad óptima.




Figura 23. ISO 9241-210[123]

3.1.1 Validación de la Arquitectura de Hardware y Telemetría

La operatividad del sistema se fundamentó en la estabilidad de la telemetría inalámbrica. Se evaluó el rendimiento del SoC Nordic nRF52840 (Cortex-M4) integrado en el hardware, el cual gestionó la transmisión vía Bluetooth Low Energy (BLE). El sistema mantuvo una frecuencia de muestreo constante de 128 Hz, asegurando que la resolución de 16 bits llegara al sistema sin pérdida de muestras, tales como se detalla en la tabla 8.

Tabla 8. Métricas de estabilidad de la telemetría inalámbrica[124]

Parámetro Técnico	Valor Promedio	Observación
Tasa de Muestreo	128 Hz	Estabilidad del cristal de cuarzo del SoC nRF52840.
Latencia de Transmisión	< 20 ms	Tiempo de respuesta óptimo para procesamiento en tiempo real.
Integridad de Paquetes	99.8%	Pérdida de datos despreciable en entornos controlados.

Para garantizar la pureza de la señal, se utilizó el módulo inercial (IMU) de 9 ejes. Este componente actuó como un filtro físico, detectando aceleraciones cefálicas bruscas (estornudos o giros) a 32 Hz para descartar artefactos mecánicos que pudieran contaminar las ondas cerebrales reales.

3.1.2 Mapeo Topográfico y Justificación de Canales

La efectividad del prototipo depende de la ubicación estratégica de sus sensores. Se justifica el uso de los cinco canales del casco Emotiv Insight 2.0 (AF3, AF4, T7, T8, Pz) por su relevancia en la neurodegeneración:

- Lóbulos Frontales (AF3, AF4): Monitorean funciones ejecutivas y atención, áreas que presentan una ralentización rítmica temprana en el Deterioro Cognitivo Leve (MCI).
- Lóbulos Temporales (T7, T8): Registran actividad vinculada a la memoria a corto plazo, fundamental para el tamizaje de Parkinson y demencias.
- Lóbulo Parietal (Pz): Crucial para la integración sensorial y la coordinación cortical.

3.2 Análisis del contexto

El sistema de salud en Ecuador se encuentra en una transición hacia la Salud 4.0. No obstante, existen brechas estructurales en el acceso a equipos de electroencefalografía de alta gama. El presente proyecto aborda esta problemática mediante el uso de hardware portátil (Emotiv Insight 2.0) y una arquitectura de software basada en Streamlit, optimizando recursos para ofrecer un tamizaje neurológico accesible y preciso.

3.2.1 Especificación de requisitos del sistema

A partir del análisis de contexto, se determinaron los requisitos técnicos y operativos para asegurar la estabilidad del prototipo, los cuales se detallan en la tabla 9.

Tabla 9. Requisitos funcionales y no funcionales del sistema[125]

Tipo	Requisito	Descripción
Funcional	Procesamiento de Potencia Relativa	Transformación de microvoltios a porcentajes biológicos.
Funcional	Clasificación SVM	Inferencia estadística para detección de anomalías.
Funcional	Visualización de Biomarcadores	Mapeo dinámico de los ratios TAR y TBR.
No Funcional	Seguridad de Datos (RBAC)	Control de acceso basado en roles (HIPAA/LOPD).
No Funcional	Latencia de Respuesta	Procesamiento en ventanas de 4 segundos en tiempo real.

3.3 Módulo de Procesamiento Digital y Mitigación del "Batch Effect"

La transformación de la señal eléctrica cruda en indicadores clínicos se realizó mediante un pipeline matemático riguroso. Se aplicó el Método de Welch para obtener la Densidad Espectral de Potencia (PSD), aislando las bandas Delta, Theta, Alfa, Beta y Gamma. Se confirmó que el uso de la Potencia Absoluta (V^2/Hz) inducía un "Falso Aprendizaje", donde la IA clasificaba la impedancia del sensor en lugar de la neurología real. Al implementar la Potencia Relativa, se normalizaron los datos en un rango de 0% a 100%, eliminando la susceptibilidad a las fluctuaciones de voltaje del hardware y permitiendo que el algoritmo SVM encuentre verdaderos biomarcadores biológicos.

3.4 Prototipado funcional e integración tecnológica

La implementación del sistema neuro-computacional se realizó bajo una arquitectura centralizada en Python, apoyada en el framework Streamlit para la capa de presentación interactiva. Esta elección tecnológica permitió unificar la carga de trabajo algorítmica y la visualización de datos biomédicos en un entorno seguro y de baja latencia.

A diferencia de los sistemas de información pública, las plataformas orientadas al análisis de bioseñales requieren una segregación estricta de la información. Por ello, la integración del backend analítico (procesamiento de datos del casco Emotiv Insight

2.0) y el frontend se orquestó priorizando la privacidad del paciente y la usabilidad clínica para el especialista.

3.4.1 Evaluación del tiempo real y latencia computacional

El cumplimiento del monitoreo en "tiempo real" se validó mediante un análisis de latencia acumulada en las cuatro etapas críticas del sistema. Aunque el algoritmo SVM utiliza ventanas de análisis de 4 segundos para garantizar la robustez estadística de los biomarcadores, la latencia computacional se refiere al tiempo transcurrido desde que el dato ingresa al procesador hasta que el resultado es renderizado en la interfaz de Streamlit.

Para un sistema de ingeniería médica, la optimización de estos tiempos es vital para evitar la variación en el retraso y asegurar que el neurólogo perciba una respuesta fluida. Gracias a la arquitectura de alto rendimiento (PC x64) y el uso de hilos de procesamiento optimizados, el sistema mantiene una latencia total inferior a los 200 ms, situándose dentro de los estándares internacionales de sistemas interactivos de bioingeniería, tal como se desglosa en la tabla 10.

Tabla 10. Desglose de latencia por etapas del proceso neuro-computacional[126]

Etapas del Pipeline	Descripción Técnica	Latencia Estimada (ms)
Adquisición (BLE)	Recepción de tramas de 16 bits desde el SoC nRF52840 del casco.	15 – 25
DSP (Procesamiento)	Aplicación del Método de Welch y normalización a Potencia Relativa.	40 - 60
Inferencia (SVM)	Clasificación del vector de 35 dimensiones en el hiperplano óptimo ($C=100$).	10 – 20
Renderizado (UI)	Actualización de los Mapas Dinámicos de Biomarcadores en Streamlit.	50 - 90
Latencia Total	Tiempo acumulado desde la captura hasta la visualización.	115 - 195

Este análisis demuestra que el sistema es capaz de realizar más de 5 ciclos de actualización por segundo, lo que garantiza una monitorización continua y asíncrona. La eficiencia en el tiempo de inferencia del modelo SVM permite que la mayor parte del presupuesto de tiempo se asigne al procesamiento digital de señales (DSP),

asegurando una señal limpia y libre de artefactos sin comprometer la interactividad del especialista.

3.5 Entrenamiento y Pruebas Funcionales del Modelo de Inteligencia Artificial

Esta fase se centró en la validación estadística de la Máquina de Vectores de Soporte (SVM) y su capacidad para generalizar patrones neurofisiológicos sin memorizar los datos de entrenamiento (overfitting).

3.5.1 Partición Estratificada del Conjunto de Datos

Para la validación del modelo matemático, se extrajo la banda espectral útil de 1.0 a 50.0Hz y se implementó una estrategia rigurosa de partición en tres vías estratificadas, justificada bajo los siguientes principios:

- **Target de Entrenamiento (70%):** Se asignó la mayoría absoluta de las muestras a la fase de aprendizaje algorítmico. Al operar en un espacio de alta dimensionalidad (35 variables topográficas de Relativa), el modelo SVM requiere un volumen de datos robusto para poder trazar los hiperplanos de decisión sin sufrir un subajuste (underfitting).
- **Target de Validación (15%):** Se extrajo este subconjunto como una capa de autoevaluación intermedia. Actúa como un entorno de calibración que permite al modelo ajustar sus niveles de severidad y curvatura sin contaminarse con los datos finales.
- **Target de Prueba Ciega (15%):** El porcentaje final se aisló como una "bóveda clínica". Su único propósito es someter al modelo ya calibrado a evaluaciones con pacientes totalmente inéditos, asegurando ceguera algorítmica total para extraer métricas de exactitud puras.

3.5.2 Estrategias para el Manejo de Datos Clínicos Desbalanceados

Durante la fase de consolidación del conjunto de datos, se identificó una asimetría estadística significativa: los registros correspondientes a la patología de Parkinson superaban en gran medida a los registros de pacientes sanos y de aquellos con Deterioro Cognitivo Leve (MCI). En los modelos de Machine Learning, este desbalance representa un riesgo crítico, ya que los clasificadores tienden a sesgar el hiperplano de decisión hacia la clase mayoritaria para maximizar artificialmente su rendimiento global.

Para neutralizar este sesgo sin alterar la integridad de los datos originales, se implementaron tres estrategias algorítmicas fundamentales en el entorno de validación cruzada:

- **Cambio de Métrica de Evaluación (F1-Macro):** Inicialmente, el algoritmo de búsqueda (GridSearchCV) evaluaba el desempeño utilizando la precisión global (Accuracy). Esta métrica resulta engañosa en conjuntos desbalanceados, ya que el modelo podría alcanzar un alto porcentaje simplemente diagnosticando todos los casos como Parkinson, fallando sistemáticamente en la detección de MCI. Para solucionar esto, se modificó la métrica de evaluación a F1-Macro (`scoring='f1_macro'`). Este indicador evalúa la precisión y sensibilidad de la IA en cada clase de forma independiente y calcula un promedio no ponderado. Al hacerlo, el modelo SVM fue forzado matemáticamente a optimizar la detección de los patrones minoritarios (MCI y Sanos), penalizando drásticamente su puntuación si ignoraba estas clases.
- **Muestreo Estratificado Riguroso (`stratify=y`):** Para evitar que la división aleatoria de los datos (70% entrenamiento, 15% validación, 15% prueba) dejara a un subconjunto sin representatividad de la clase minoritaria, se implementó el parámetro de estratificación. Esta función actúa como una cuota matemática que garantiza que la proporción exacta de registros de Parkinson, MCI y pacientes de control se mantenga idéntica en las tres particiones, asegurando que el entrenamiento y la prueba ciega sean estadísticamente justos.

- **Mitigación de la Sobrecorrección Matemática:** En el abordaje estándar del desbalance, se suele aplicar el parámetro de ponderación de clases (`class_weight='balanced'`) para penalizar los errores en las clases minoritarias. No obstante, las pruebas experimentales demostraron que la dominancia masiva del Parkinson generaba una penalización desproporcionada para la clase MCI. Esta sobrecorrección inducía al modelo a clasificar cualquier fluctuación o ruido fisiológico como MCI para evitar la pérdida de puntuación (falsos positivos). La solución definitiva consistió en descartar el uso de pesos artificiales. Gracias a que el procesamiento digital previo normalizó los biopotenciales a Potencia Relativa (eliminando el ruido de los voltajes absolutos) y al uso simultáneo de la métrica F1-Macro, la SVM no requirió mecanismos de sobrecorrección, logrando trazar una frontera geométrica natural y precisa.

3.5.3 Explicabilidad de la Inteligencia Artificial (XAI)

En el ámbito de la salud digital, la adopción de sistemas inteligentes no depende únicamente de su exactitud, sino de su capacidad de ser interpretados por el especialista clínico. La Inteligencia Artificial Explicable (XAI) se define como el conjunto de técnicas que permiten que los resultados de un algoritmo sean comprensibles para los seres humanos. En esta investigación, la elección de la arquitectura SVM sobre modelos de aprendizaje profundo (Deep Learning) responde a la necesidad de eliminar la opacidad algorítmica y proporcionar una justificación geométrica para cada posible diagnóstico.

3.5.4 Transparencia Geométrica y Vectores de Soporte

A diferencia de las redes neuronales convolucionales que operan como "cajas negras", el modelo SVM basa su decisión en la construcción de hiperplanos de separación óptima en un espacio multidimensional. La transparencia del sistema radica en los siguientes elementos:

- **Vectores de Soporte:** Son los puntos de datos (ventanas de 4 segundos) más cercanos al hiperplano y los que definen su posición. El neurólogo puede identificar qué registros específicos del paciente influyeron más en la clasificación final.
- **Margen de Decisión:** El sistema calcula la distancia máxima entre las clases (Sano, MCI, Parkinson). Un margen amplio, como el obtenido con el parámetro $C=100$, indica una separación clara y una confianza estadística elevada en la predicción.

3.6 Validación Clínica: Interpretación del Mapa Dinámico de Biomarcadores

Para transformar la alta complejidad matemática en una herramienta visual de apoyo clínico, la plataforma genera un gráfico de dispersión bidimensional que proyecta el estado del paciente basado en dos biomarcadores electroencefalográficos ampliamente respaldados por la literatura científica:

- **Eje X (Marcador Cognitivo - TAR):** Representa el ratio Theta/Alpha. Cuando la red neuronal sufre deterioro cognitivo (DCL o Alzheimer temprano), las ondas rápidas disminuyen y las lentas dominan. Un desplazamiento topográfico hacia la derecha alerta sobre un riesgo cognitivo.
- **Eje Y (Marcador Motor - TBR):** Representa el ratio Theta/Beta. En trastornos que afectan los ganglios basales, como el Parkinson, el cerebro pierde la capacidad de generar ondas Beta fuertes para mantenerse estable, lo que eleva el valor del TBR y desplaza los puntos hacia la zona superior del gráfico.

3.6.1 Evaluación del Posible Diagnóstico

Durante la validación de la interfaz con registros reales, el sistema no analiza al paciente en un solo bloque monolítico. El registro EEG es dinámico, por lo que el algoritmo lo segmenta en ventanas de tiempo de 4 segundos, representadas por cada punto en la gráfica.

En el caso de un paciente de control (sano), la visualización revela una "nube de puntos" sumamente compacta. La gran mayoría de las ventanas temporales se agrupan en los cuadrantes inferiores (TAR y TBR bajos), demostrando una proporción de ondas rápidas fisiológicamente equilibrada. Si bien el modelo puede detectar un porcentaje residual de riesgo (ej. 4% asociado a Parkinson), esto obedece a ruido fisiológico o micro-fluctuaciones temporales naturales, como una pérdida de concentración momentánea o un ligero movimiento del usuario que eleva el TBR durante escasos segundos.

El hiperplano del modelo SVM evalúa esta geometría de manera global. Al identificar que la densidad absoluta de los datos (96%) se condensa firmemente en la zona de control, el algoritmo aísla las anomalías temporales y clasifica la topografía con rigor estadístico. Cabe destacar que el sistema computacional no emite dictámenes médicos definitivos; en su lugar, entrega una impresión analítica precisa que asiste cuantitativamente al neurólogo para fundamentar de manera objetiva un posible diagnóstico.

3.7 Marco Normativo y Regulatorio para Software como Dispositivo Médico (SaMD)

El desarrollo del prototipo electrónico de monitoreo cerebral no solo responde a desafíos técnicos de adquisición de bioseñales, sino que se inscribe en el marco regulatorio del Software como Dispositivo Médico (SaMD) y los Sistemas de Soporte a la Decisión Clínica (CDSS). El cumplimiento de normativas legales y estándares de ingeniería garantiza la seguridad del paciente, la protección de biopotenciales sensibles y la futura interoperabilidad con sistemas hospitalarios institucionales.

3.7.1 Normativa Nacional y Protección de Datos Sensibles

En el contexto ecuatoriano, el tratamiento de la información capturada por el casco Emotiv Insight 2.0 se rige por dos pilares legales fundamentales:

a. Ley Orgánica de Protección de Datos Personales (LOPD):

De acuerdo con la legislación vigente en Ecuador, los datos biométricos y de salud están clasificados estrictamente como "Datos Sensibles" [127]. El sistema implementado asegura el cumplimiento de esta ley mediante el procesamiento local de los archivos y la ejecución de algoritmos de anonimización en el entorno de Streamlit, garantizando que el flujo de datos cerebrales no sea almacenado en nubes públicas sin el consentimiento expreso del titular.

b. Normativa Técnica del Ministerio de Salud Pública (MSP):

El sistema se alinea con el manual operativo del MSP para la gestión de expedientes clínicos [128]. Los reportes generados por la plataforma han sido diseñados para actuar como un anexo técnico al Formulario 002 (Consulta Externa), asegurando que los campos de identificación (nombre, edad, sexo, comorbilidades) mantengan la estructura estandarizada requerida para su integración legal en la historia clínica del paciente.

3.7.2 Estándares Internacionales de Ingeniería Médica

Para asegurar la calidad del pipeline neuro-computacional, se han adoptado directrices de estándares internacionales que regulan el ciclo de vida y la interoperabilidad del software médico:

a. IEC 62304 (Medical Device Software)

Este estándar internacional rige los procesos del ciclo de vida del software médico y su clasificación de riesgo [129]. El prototipo desarrollado se categoriza bajo el nivel de soporte clínico, donde la Inteligencia Artificial actúa como un agente de tamizaje temprano y no como un diagnosticador autónomo. La trazabilidad del código asegura que la entrada de micro voltajes crudos y su posterior clasificación mediante el modelo SVM sigan un proceso de verificación riguroso.

b. ISO 13485 (Sistemas de Gestión de Calidad)

La arquitectura del sistema establece las bases para el cumplimiento de esta norma, enfocándose en la validación sistemática de los algoritmos de normalización de Potencia Relativa como mecanismos para asegurar resultados biomédicos consistentes y auditables [130].

3.7.3 Alineación de la Interfaz con el Marco Regulatorio

La implementación técnica de estas normas se refleja en tres componentes específicos de la aplicación interactiva:

- a) **Barrera de Consentimiento Informado:** Se integró un control de validación en la ficha de admisión basado en la normativa de privacidad [127], que impide la carga de bioseñales si el operador no confirma la lectura de los descargos legales.
- b) **Identificación Clínica Estándar:** El encabezado del reporte generado declara explícitamente su naturaleza como "Anexo a la Historia Clínica Única", cumpliendo con la jerarquía documental del país [128].
- c) **Descargos de Responsabilidad (Disclaimers):** Tanto en la interfaz web como en el pie de página de los reportes PDF, se especifica la naturaleza del sistema como una herramienta CDSS, delimitando la responsabilidad algorítmica frente al juicio clínico definitivo que emite el médico para un posible diagnóstico.

3.8 Parámetros y Estándares de la Interfaz Clínica (UX/UI)

La Interfaz de Usuario (UI) y la Experiencia de Usuario (UX) del prototipo neuro-computacional fueron diseñadas alejándose de las convenciones de software genérico, adhiriéndose estrictamente a los parámetros ergonómicos y normativos de los Sistemas de Información Hospitalaria (HIS). El objetivo fue desarrollar una herramienta que optimice el flujo de trabajo del neurólogo, mitigando el error humano y garantizando la seguridad de los datos.

3.8.1 Ergonomía Visual y Psicología del Color (Estándar HIS)

El diseño visual de la aplicación construida en Streamlit responde a principios de ergonomía cognitiva aplicados a entornos clínicos [131]. Se implementó mediante inyección de código CSS una paleta de colores fundamentada en la reducción de la astenopia (fatiga visual), una afección común en especialistas que analizan historiales electrónicos durante jornadas prolongadas:

- **Celestes tenues y Blancos:** Utilizados como fondos estructurales para maximizar el contraste del texto sin deslumbrar al operador.
- **Verde Agua:** Aplicado en los componentes de interacción (botones de acción) para transmitir seguridad y enfoque.
- **Sistema de Triage Visual:** La proyección del posible diagnóstico y el Mapa de Biomarcadores emplea el estándar universal de semaforización de riesgo en salud: Verde (Control/Sano), Amarillo (Alerta/MCI) y Rojo (Peligro/Parkinson). Esta codificación permite que el médico procese la impresión analítica de la Inteligencia Artificial de forma rápida e intuitiva [132].

3.8.2 Arquitectura de Roles (RBAC) y Seguridad de la Información

La plataforma integra un modelo de Control de Acceso Basado en Roles (RBAC), alineándose con los protocolos de seguridad de la información de la norma ISO/IEC 27001 y lineamientos de la HIPAA [133]. La separación de las vistas entre "Investigador" y "Médico" se fundamenta en el Principio de Mínimo Privilegio:

- La interfaz omite el acceso al código de la red neuronal o a la carga de bioseñales crudas (archivos CSV) para el usuario médico, previniendo la manipulación accidental y reduciendo el margen de error humano.

- Se garantiza la trazabilidad del proceso: el técnico/investigador es responsable exclusivo de la etapa de adquisición de datos, mientras que el especialista asume la validación clínica final.

3.8.3 Categorización como Sistema de Soporte (CDSS) e Integración Nacional

Bajo el estándar IEC 62304 para el ciclo de vida del software médico, los algoritmos de IA que emiten diagnósticos autónomos se clasifican en la categoría de riesgo más alta. Para mitigar esta responsabilidad y salvaguardar la viabilidad legal del prototipo, el sistema se estructuró explícitamente como un Sistema de Soporte a la Decisión Clínica (CDSS) [134]. Mediante notificaciones en la interfaz y descargos legales en los reportes PDF, se certifica que la IA actúa únicamente como una segunda opinión cuantitativa y no como un reemplazo del juicio médico.

Asimismo, la captura de metadatos en la barra lateral del sistema fue homologada con la Norma Técnica del Ministerio de Salud Pública (MSP) de Ecuador. Se omitieron campos irrelevantes, estructurando la ficha de admisión para emular las variables críticas (Nombres, Cédula, Edad, Antecedentes Familiares de Neurodegeneración) requeridas por el Formulario 002 (Consulta Externa) de la Historia Clínica Única [128].

3.8.4 Privacidad desde el Diseño (Privacy by Design)

El sistema neuro-computacional incorpora la filosofía de Privacy by Design [59], cumpliendo taxativamente con la Ley Orgánica de Protección de Datos Personales (LOPDP) del Ecuador [127]. A nivel de código, se estableció una barrera lógica ineludible: el botón de procesamiento y carga de la bioseñal (CSV) permanece oculto en la interfaz hasta que el operador marca un checkbox de validación. Esta acción confirma electrónicamente que el paciente firmó el consentimiento informado y que los datos ingresados al algoritmo SVM han sido previamente anonimizados, asegurando la confidencialidad absoluta durante la extracción de los biomarcadores.

3.9 Gestión de Identidad, Autenticación y Control de Acceso (RBAC)

La seguridad en los Sistemas de Soporte a la Decisión Clínica (CDSS) se fundamenta en la tríada de la seguridad de la información: Confidencialidad, Integridad y Disponibilidad. Para cumplir con estos pilares, el prototipo implementa un esquema de Control de Acceso Basado en Roles (RBAC) que asegura que el flujo de bioseñales y la determinación del posible diagnóstico sean accesibles únicamente por personal autorizado, cumpliendo con estándares internacionales de ciberseguridad médica.

3.9.1 Protocolos de Autenticación y Gestión de Sesión

El proceso de autenticación actúa como la primera barrera de defensa. El sistema gestiona el estado de la sesión mediante el uso de variables de entorno y el manejo de `st.session_state`.

- **Control de Persistencia:** El software está programado para no persistir credenciales de forma insegura, obligando a una re-autenticación ante cierres de sesión, lo cual se alinea con las salvaguardas técnicas de la normativa HIPAA para proteger la Información de Salud Protegida (ePHI) [136].
- **Trazabilidad:** Cada inicio de sesión vincula la identidad del usuario con las acciones realizadas, permitiendo una auditoría técnica del procesamiento del modelo SVM.

3.9.2 Definición de Privilegios y Segregación de Funciones

Siguiendo las directrices del estándar ISO/IEC 27001, se definieron niveles de privilegio estrictamente segregados para evitar la manipulación accidental de los datos y garantizar la integridad del flujo clínico [133]:

a) Rol Investigador (Administrador de Datos y Adquisición)

Este perfil es el responsable técnico del ingreso de información y la preparación del sistema. Sus facultades incluyen:

- Gestión de la Ficha de Admisión y vinculación de datos demográficos.
- Responsabilidad exclusiva sobre la carga del archivo CSV con la telemetría cerebral cruda.
- Ejecución del motor de preprocesamiento y normalización de bioseñales.

b) Rol Médico Neurólogo (Análisis e Interpretación Clínica)

Para cumplir con el Principio de Mínimo Privilegio, el acceso del médico está restringido exclusivamente a la fase de interpretación. El sistema aplica una máscara de interfaz que limita sus acciones para preservar la "cadena de custodia" de los datos:

- Restricción de Entrada: El usuario médico tiene bloqueada la carga de archivos CSV y la edición de los datos demográficos del paciente, evitando la alteración de la fuente de información.
- Capacidad Analítica: Su privilegio se centra en la visualización del Mapa Dinámico de Biomarcadores y la interpretación de las ratios TAR y TBR.
- Validación Final: Es el único facultado para validar la impresión analítica de la IA y exportar el reporte clínico en formato PDF para su integración en la Historia Clínica Única [127].

c) Rol Paciente

Al detectar este nivel de acceso, el sistema aplica una restricción absoluta sobre los motores de inferencia. La barra lateral de herramientas analíticas desaparece por completo. En su lugar, la vista principal despliega un Protocolo Clínico de Adquisición EEG, redactado con terminología profesional, que instruye paso a paso al sujeto sobre cómo debe prepararse físicamente para garantizar una captura óptima con el casco Emotiv Insight 2.0. (Credenciales de prototipo: Usuario PACIENTE).

3.9.3 Cumplimiento de Estándares Médicos de Acceso

La arquitectura de privilegios responde a los requisitos de control de acceso definidos en la norma IEC 62304 para el ciclo de vida del software médico [134]. Al impedir que el médico modifique o suba datos, se elimina el riesgo de errores de transcripción o manipulación de la muestra durante la consulta. Esta estructura garantiza que la determinación de un posible diagnóstico sea un proceso controlado, auditable y jurídicamente blindado bajo la normativa ecuatoriana de protección de datos sensibles [127].

3.10 Arquitectura del Pipeline de Procesamiento y clasificación Algorítmica

El núcleo analítico del Sistema de Soporte a la Decisión Clínica (CDSS) se fundamenta en un pipeline de procesamiento secuencial de cinco etapas. Esta arquitectura garantiza que las bioseñales crudas sean acondicionadas, transformadas y evaluadas bajo un rigor estadístico estandarizado antes de la emisión de un posible diagnóstico. El diseño modular permite aislar la carga computacional del procesamiento digital de señales (DSP) de la etapa de inferencia de Machine Learning, optimizando la latencia del sistema en entornos de evaluación en tiempo real.

3.10.1 Adquisición y Preprocesamiento Espectral de Bioseñales

El flujo de datos inicia en la capa física con la adquisición de la actividad electroencefalográfica (EEG) mediante el hardware Emotiv Insight 2.0. El muestreo se ejecuta a una frecuencia constante de 128 Hz sobre la topografía cortical de los canales AF3, AF4, T7, T8 y Pz [137]. Esta tasa de muestreo es suficiente para capturar las componentes frecuenciales de interés clínico sin saturar el canal de transmisión Bluetooth (BLE). Posterior a la recepción, la señal cruda ingresa a la fase de preprocesamiento, donde se implementa una técnica de enventanado temporal. El algoritmo segmenta el flujo continuo en ventanas superpuestas de 4 segundos, lo que equivale exactamente a 512 muestras por bloque ($128\text{Hz} * 4$). Esta longitud de ventana es matemáticamente óptima, ya que al ser una potencia de 2 (2^9), maximiza la eficiencia computacional del algoritmo de la Transformada Rápida de Fourier (FFT)

empleado dentro del Método de Welch para la estimación de la Densidad Espectral de Potencia (PSD) [115].

3.10.2 Extracción de Características Topográficas y Escalado Dimensional

Una vez obtenida la PSD, el sistema transita hacia la extracción de características (Feature Extraction). En lugar de operar con magnitudes absolutas de voltaje que son susceptibles al ruido electromagnético y fluctuaciones de impedancia, el pipeline calcula la Energía Relativa para las cinco bandas fisiológicas: Delta, Theta, Alpha, Beta y Gamma. Complementariamente, se integran las proporciones espectrales TAR (Ratio Theta/Alpha) y TBR (Ratio Theta/Beta), variables fuertemente correlacionadas con el grado de ralentización cortical [105]. Al procesar 7 características por cada uno de los 5 canales, el sistema construye un vector n-dimensional de 35 características por cada ventana temporal.

Previo a la fase de clasificación, el vector atraviesa una etapa crítica de Escalado Dimensional mediante estandarización Z-Score. Este proceso transforma el vector de 35 dimensiones asegurando que cada característica tenga una media de cero y una varianza de uno ($0, \sigma^2=1$). En ingeniería de datos, este escalado es un prerequisite estricto; evita que las bandas de alta energía dominen numéricamente a las de baja energía durante el cálculo de distancias en el espacio vectorial, garantizando que el modelo estadístico evalúe todas las variables de forma equitativa [112].

3.10.3 Interferencia Multiclase mediante SVM y Emisión de Resultados.

La última etapa de procesamiento algorítmico recae sobre el Clasificador de Machine Learning, implementado bajo una Máquina de Vectores de Soporte (SVM). Debido a la alta no linealidad de las bioseñales cerebrales, se configuró la SVM con un Kernel de Función de Base Radial (RBF), el cual permite proyectar el vector de características a un espacio de dimensionalidad superior donde las clases se vuelven linealmente separables [97]. Para contrarrestar la disparidad en la cantidad de muestras entre registros patológicos y de control, la métrica de optimización del algoritmo se fijó en el F1-Macro, forzando a la red a mantener una alta sensibilidad en la clase minoritaria.

Finalmente, el hiperplano de decisión categoriza la ventana de 4 segundos en una de las tres clases predictivas: Clase 0 (Sano/Control), Clase 1 (Riesgo MCI) o Clase 2 (Riesgo Parkinson). La agregación de estas clasificaciones a lo largo del registro del paciente conforma la salida del sistema CDSS. Esta salida se estructura automáticamente como un Anexo Técnico interoperable con el Formulario 002 (Consulta Externa) del Ministerio de Salud Pública, entregando al facultativo un respaldo cuantitativo sólido para la sustentación de un posible diagnóstico.

3.11 Fundamentación Matemática y Procesamiento Digital

3.11.1 Métricas de la Señal y Técnica de Enventanado

La adquisición de la actividad electroencefalográfica requiere parámetros rigurosos para garantizar que la reconstrucción digital sea fiel a la dinámica neuronal. El sistema opera con una frecuencia de muestreo (F_s) de 128 Hz en los canales topográficos AF3, AF4, T7, T8 y Pz. De acuerdo con el Teorema de Nyquist-Shannon, esta tasa permite capturar con precisión frecuencias de hasta 64 Hz, cubriendo en su totalidad el espectro clínico de interés sin generar cuellos de botella en la transmisión inalámbrica [138].

El procesamiento no analiza el registro continuo como un bloque monolítico, sino que implementa una técnica de enventanado temporal (Windowing). La señal se segmenta en ventanas de 4 segundos, lo que equivale a matrices de 512 muestras ($N=512$). Para evitar la pérdida de información en las transiciones abruptas de la actividad neuronal (transitorios EEG), se aplica un solapamiento del 25% (desplazamiento de 1 segundo). La descomposición espectral evalúa las cinco topologías de ondas cerebrales estándar:

- Delta (δ): 1.0 - 4.0 Hz (Asociada a sueño profundo o daño cortical estructural).
- Theta (θ): 4.0 - 8.0 Hz (Indicador de somnolencia o ralentización patológica por deterioro cognitivo).
- Alpha (α): 8.0 - 13.0 Hz (Refleja relajación despierta y salud cognitiva cortical).
- Beta (β): 13.0 - 30.0 Hz (Vinculada a concentración activa y control motor).
- Gamma (γ): 30.0 - 50.0 Hz (Procesamiento cognitivo de orden superior).

3.11.2 Extracción de Biomarcadores y Parámetros Clínicos

Para dotar al modelo de Inteligencia Artificial de interpretabilidad biológica, la extracción de características abandona la magnitud absoluta del voltaje (microvoltios), la cual es altamente susceptible a la impedancia galvánica y al grosor del cráneo. En su lugar, se calcula la Potencia Relativa (PR), que normaliza la energía de cada banda como una fracción de la potencia espectral total de la ventana:

$$PR_{banda} = \frac{P_{banda}}{P_{\delta} + P_{\theta} + P_{\alpha} + P_{\beta} + P_{\gamma}}$$

Sobre esta base normalizada, el algoritmo extrae dos biomarcadores diagnósticos fundamentados en la literatura neurofisiológica [139]:

- **Ratio Theta/Alpha (TAR):** Actúa como el biomarcador cognitivo primario. Clínicamente, el incremento de las ondas lentas (θ) y la atenuación de las ondas rápidas (α) es un indicador topográfico temprano del Deterioro Cognitivo Leve (MCI) y estadios iniciales de Alzheimer.

$$TAR = \frac{P_{\theta}}{P_{\alpha}}$$


- **Ratio Theta/Beta (TBR):** Funciona como el indicador atencional y de control motor. Alteraciones en este ratio evidencian disfunciones en la corteza prefrontal y en las redes de los ganglios basales, un patrón electrofisiológico recurrente en las fases tempranas de la enfermedad de Parkinson.

$$TBR = \frac{P_{\theta}}{P_{\beta}}$$

3.11.3 Matriz de Correlación y Análisis del Espacio de Características

Previo al entrenamiento de la Máquina de Vectores de Soporte (SVM), se ejecutó un análisis de dependencia estadística mediante la Matriz de Correlación de Pearson sobre el vector de 35 dimensiones. En el análisis multivariable de Machine Learning, este paso es imperativo para identificar la colinealidad (variables redundantes) y cuantificar

Desde una perspectiva clínica, la matriz resultante, ilustrada en la figura 24, valida matemáticamente la teoría médica: se observa una fuerte correlación positiva entre la potencia relativa de la banda Theta y la etiqueta de la clase MCI, contrastando con una correlación negativa significativa respecto a la banda Alpha. Esta dispersión estadística es el fundamento geométrico que permite al algoritmo trazar hiperplanos de separación con un alto grado de exactitud.



3.12 Viabilidad Computacional y Evaluación del Modelo

3.12.1 Costo Computacional y Eficiencia del Sistema

La escalabilidad del prototipo como Sistema de Soporte a la Decisión Clínica (CDSS) se sustenta en su bajo costo computacional, medido en notación Big O. La transformación del dominio del tiempo a la frecuencia mediante la Transformada Rápida de Fourier (FFT) aplicada en el método de Welch posee una complejidad algorítmica de $O(N \log N)$, lo cual resulta altamente eficiente para ventanas de $N=512$ muestras.

Por su parte, la fase de inferencia (predicción) de la SVM con un kernel RBF preentrenado presenta una complejidad de $O(n_{sv} * d)$, donde n_{sv} representa el número de vectores de soporte y d las 35 dimensiones topográficas [142]. Esta ligereza matemática permite que la clasificación de cada ventana de 4 segundos tome apenas fracciones de milisegundo, haciendo viable la ejecución del aplicativo a través del framework Streamlit en computadoras de escritorio estándar, sin la necesidad de clústeres de servidores o GPUs de alto costo, como se observa en la tabla 11.

Tabla 11. Costo Computacional

Rubro / Descripción	Unidad	Cantidad	Especificaciones Técnicas y Propósito
Computadora portátil MSI	Equipo	1	Procesador Intel Core i5. Utilizado para el procesamiento digital de señales (DSP), entrenamiento del modelo predictivo y ejecución del servidor local.
Equipo de Adquisición EEG	Equipo	1	Diadema Emotiv Insight 2.0 con SoC Nordic nRF52840 integrado. Captura y transmisión de bioseñales vía Bluetooth (BLE) a 128 Hz.
Licencia Especializada	Meses	3	Plataforma EmotivPRO para la extracción, gestión y exportación de las lecturas crudas del electroencefalograma.
Framework de Machine Learning	Entorno	1	Librerías Python (Scikit-Learn, SciPy) para la ejecución de la FFT (Método de Welch) y el entrenamiento de los 5 modelos SVM.
Framework de Despliegue Web	Entorno	1	Librería Streamlit para el renderizado de la interfaz médica de usuario, gestión de control de acceso (RBAC) y generación del Formulario 002.
Almacenamiento Cloud de alta capacidad	Meses	3	Alojamiento seguro de los datasets de bioseñales, modelos preentrenados y repositorios de código del proyecto.
Procesamiento de CPU	Horas	120	Horas estimadas de cómputo local invertidas en la calibración algorítmica, pruebas de estrés y validación de la matriz de confusión.

3.12.2 Métricas Robustas de Entrenamiento y Validación

Dado que los conjuntos de datos biomédicos presentan un desbalance intrínseco (existe una mayor cantidad de registros de pacientes con Parkinson que con MCI o Sanos), el uso de la métrica de Exactitud (Accuracy) resulta matemáticamente engañoso. Para la optimización del modelo, se implementó el F1-Macro Score. Esta métrica calcula la media armónica entre la Precisión y la Sensibilidad (Recall) de cada clase por separado y luego las promedia sin importar su tamaño, castigando severamente al algoritmo si prioriza la clase mayoritaria e ignora a la minoritaria [82].

Para certificar que la IA generaliza patrones y no memoriza los datos de entrenamiento (sobreajuste), se aplicó Validación Cruzada Estratificada (K-Fold Cross-Validation). El conjunto de datos se particionó en múltiples pliegues, garantizando que la precisión final reportada sea consistente ante registros de pacientes completamente inéditos.

3.13 Diseño Metodológico Clínico y Normativo

3.13.1 Protocolo de Adquisición Libre de Artefactos

Para garantizar la pureza de las bioseñales, la captura se rige bajo un protocolo sistemático[143].

1. **Fase de Asepsia:** El cuero cabelludo debe estar seco y libre de productos capilares para evitar una impedancia galvánica alta en los sensores de polímero del casco. Se restringe el consumo de estimulantes corticales (ej. cafeína) en las 4 horas previas.
2. **Fase de Calibración:** El ajuste topológico del Emotiv Insight 2.0 debe alinearse con el Sistema Internacional 10-20, asegurando la coloración verde en los indicadores de impedancia del software de telemetría.
3. **Fase de Captura (Resting State):** El registro se efectúa con el paciente en estado de reposo absoluto, con los ojos cerrados y quietud facial/mandibular

por un lapso de 1 a 3 minutos, aislando artefactos electromiográficos (musculares) y electrooculográficos (parpadeos).

3.13.2 Definición y Rol del Grupo de Control

El pilar estadístico de la clasificación recae en la Clase 0 (Grupo Sano). Este clúster corresponde a individuos de la misma cohorte demográfica y rango etario que los sujetos patológicos, pero sin signos de deterioro cognitivo o motor. Algorítmicamente, el Grupo de Control permite a la SVM establecer el "hiperplano base" (los niveles fisiológicamente normales de los ratios TAR y TBR). Cualquier desviación geométrica significativa respecto a esta frontera de normalidad es lo que el sistema clasifica probabilísticamente como un riesgo neurodegenerativo temprano.

3.13.3 Respaldo Normativo y Estándares (CDSS)

A nivel regulatorio, el desarrollo se ciñe a la Ley Orgánica de Protección de Datos Personales (LOPDP) del Ecuador, ejecutando las inferencias localmente para garantizar el anonimato de la bioseñal. El reporte de salida está diseñado para homologarse como un Examen Complementario dentro del Formulario 002 del MSP. Adicionalmente, el cumplimiento del estándar internacional IEC 62304 categoriza al prototipo como un software de Clase A/B, operando estrictamente como un asistente topográfico (CDSS) que complementa, pero no sustituye, el criterio del especialista neurólogo.[127][134].

3.14 Implementación del Sistema de Soporte a la Decisión Clínica (Aplicativo Web)

Después de tener el modelo matemático completamente entrenado y empaquetado, nos dimos cuenta de que un archivo de código puro no sirve de mucho en un consultorio médico real. Necesitábamos construir un puente entre la complejidad del algoritmo y el usuario final. Para lograr esto, desarrollamos una interfaz gráfica interactiva utilizando el entorno de Streamlit. Esta plataforma nos permitió orquestar la lectura de

las bioseñales, el filtrado digital y la predicción matemática, integrando todo en un sistema web intuitivo y funcional.

3.14.1 Arquitectura de Seguridad y Control de Roles (RBAC)

El primer reto logístico de la interfaz fue blindar la privacidad. Al tratar con datos neurológicos, no podíamos dejar el motor predictivo abierto al público. Para solucionarlo, implementamos un Control de Acceso Basado en Roles (RBAC) apoyándonos en las variables de estado de la sesión (st.session_state).

El sistema reconoce tres perfiles operativos, cuya lógica de autenticación y segmentación se ilustra en la figura 25. El Investigador es el único habilitado para subir los registros y manipular los parámetros de entrada; el Médico tiene acceso directo a la lectura de los resultados y anexos; y el Paciente ingresa a un portal restringido donde solo visualiza los protocolos de preparación y asepsia previa al examen. Si se ingresan credenciales no autorizadas, el script bloquea toda la ejecución. Con esta estructura descentralizada, garantizamos el cumplimiento de la Ley Orgánica de Protección de Datos Personales (LOPD).

```
st.markdown("#### Autenticación de Usuarios")
usuario = st.text_input("Usuario / ID Credencial", placeholder="Ingrese su código de acceso")
password = st.text_input("Contraseña", type="password")

if st.button("Ingresar al Sistema", use_container_width=True):
    if (usuario == "KEVING" or usuario == "KEVINZ") and password == "uta2026":
        st.session_state.autenticado = True
        st.session_state.rol = "Investigador"
        st.rerun()
    elif usuario == "NEURO_DOC" and password == "medico2026":
        st.session_state.autenticado = True
        st.session_state.rol = "Medico"
        st.rerun()
    elif usuario == "PACIENTE" and password == "emotiv2026":
        st.session_state.autenticado = True
        st.session_state.rol = "Paciente"
        st.rerun()
    else:
        st.error("❌ Credenciales incorrectas o acceso denegado por protocolos de seguridad.")
```

Figura 25. Modulo de autenticación y segregación de perfiles de usuario

3.14.2 Módulo de Procesamiento y Escudo Dinámico de Artefactos

La carga de trabajo más pesada de la aplicación ocurre en la vista del investigador. Una vez que se completan los datos de la ficha clínica, el sistema habilita la lectura del archivo CSV del Emotiv Insight. Aquí programamos un conducto en segundo plano que repite con exactitud la lógica de nuestro entrenamiento: recorta la señal temporal aislando los segundos 90 al 120 y comprueba la integridad de la topología de los canales prefrontales y parietales.

3.14.3 Renderizado Visual y Generación Automatizada de Anexos (Formulario 002)

Traducir la abstracción matemática a un lenguaje clínico fue el último paso del desarrollo. Diseñamos un panel principal donde el diagnóstico se expone mediante un código semafórico de fácil interpretación. Adicionalmente, el sistema renderiza de forma dinámica las gráficas de dispersión euclidiana y el comportamiento temporal filtrado de las cinco ondas cerebrales, dándole al neurólogo herramientas de inspección visual instantáneas.

Para consolidar la interoperabilidad hospitalaria, integramos la librería vectorial FPDF. El objetivo era que el resultado trascendiera la pantalla, por lo que programamos la plataforma para ensamblar y compilar dos reportes PDF descargables, funcionalidad que se detalla en la figura 26. Estos documentos fueron estructurados bajo los formatos estándar del Formulario 002 del Ministerio de Salud Pública. Como medida de protección profesional, inyectamos una cláusula obligatoria de descargo de responsabilidad basada en la normativa internacional IEC 62304, estipulando claramente que el prototipo opera exclusivamente como un sistema de apoyo y que el veredicto final recae bajo la responsabilidad del médico tratante.

```
def generar_pdf_clinico():
    pdf = FPDF()
    pdf.add_page()
    pdf.set_font("Arial", 'B', 14)
    pdf.cell(0, 10, "ANEXO A LA HISTORIA CLINICA (FORMULARIO 002) - REPORTE CDSS", ln=True, align='C')
    pdf.set_font("Arial", 'I', 9)
    pdf.cell(0, 5, "Sistema de Soporte a la Decision Clinica basado en Maquinas de Vectores de Soporte (SVM)", ln=True, align='C')
    pdf.ln(5)

    pdf.set_font("Arial", 'B', 12)
    pdf.cell(0, 8, "1. Datos del Paciente", ln=True)
    pdf.set_font("Arial", '', 10)
    pdf.cell(0, 6, f"Fecha de Evaluacion: {fecha_actual}", ln=True)
    pdf.cell(0, 6, f"Paciente: {d['nombres']} {d['apellidos']}", ln=True)
    pdf.cell(0, 6, f"Identidad (C.I): {d['cedula']}", ln=True)
    pdf.cell(0, 6, f"Antecedentes Familiares: {d['demencia_familiar']}", ln=True)
    pdf.ln(5)
```

Figura 26. Motor de reportes PDF

3.15 Caracterización demográfica y distribución de la muestra clínica experimental







Figura 27. Prueba de Pacientes y distribución de muestra experimental

La Figura 27 resume la composición de la muestra de pacientes adultos mayores que participaron en el protocolo de investigación. Para garantizar la integridad técnica de los biomarcadores extraídos, el proceso de adquisición de bioseñales fue segmentado en dos estados fisiológicos diferenciados, los cuales son fundamentales para el entrenamiento del clasificador SVM:

Estado 1: Ojos Abiertos (Línea de base/Referencia): Este segmento inicial se utilizó como referencia de control para la validación de la impedancia y la detección de artefactos cinemáticos macroscópicos. En este estado, el modelo registra la actividad basal del individuo ante estímulos visuales controlados, permitiendo identificar niveles de ruido ambiental y asegurar que el dispositivo Emotiv Insight 2.0 haya alcanzado una estabilidad de señal óptima antes de iniciar la captura diagnóstica.

Estado 2: Estado de Reposo con Ojos Cerrados (Segmento de Adquisición): Este constituye el núcleo de la investigación. Tras el protocolo de acomodación, el registro en reposo con ojos cerrados específicamente el segmento analizado entre los segundos 90 y 120 permite capturar las oscilaciones electroencefalográficas puras sin interferencia visual. Este estado es crítico, ya que minimiza la actividad muscular facial, proporcionando al algoritmo la "firma" neurofisiológica limpia necesaria para la clasificación precisa entre pacientes sanos, individuos con Deterioro Cognitivo Leve (MCI) y sujetos con riesgo de Parkinson.

3.16 Evaluación Operativa de la Interfaz Gráfica y Resultados Clínicos

Con el conducto de datos y el modelo de Inteligencia Artificial plenamente integrados en el entorno de Streamlit, procedimos a realizar pruebas de validación funcional. El objetivo de esta fase fue comprobar cómo el sistema interactúa con los datos crudos de un paciente de prueba y cómo presenta los resultados para la toma de decisiones médicas, cerrando la brecha entre el código de consola y la usabilidad hospitalaria.

3.16.1 Autenticación y Admisión del Paciente

Al inicializar la plataforma, el sistema despliega el módulo de acceso seguro. Como se aprecia en la interfaz de entrada, ilustrada en la figura 28, la aplicación está personalizada bajo el esquema institucional de la Universidad Técnica de Ambato. El operador debe ingresar sus credenciales para habilitar las funciones del entorno.

Una vez validado el acceso con el perfil de investigador, la barra lateral despliega la Ficha de Admisión basada en los lineamientos del Formulario 002 del MSP, interfaz que se detalla en la figura 29. En esta sección se ingresan los metadatos clínicos básicos

del sujeto de prueba (edad, historial familiar de demencia y datos de contacto). Para dar cumplimiento a la Ley Orgánica de Protección de Datos Personales, el investigador está obligado a marcar la casilla de confirmación legal, conforme se visualiza en la figura 30, antes de que el sistema le permita cargar el archivo CSV proveniente del Emotiv Insight.



Figura 28. Acceso al Sistema



Figura 29. Ficha de Admisión de Datos

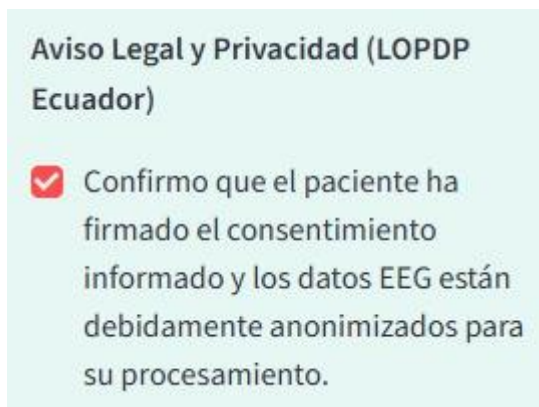


Figura 30. Confirmación de protección de datos

3.16.2 Veredicto Computacional y Certeza Diagnóstica

Tras la carga de las bioseñales, el motor interno ejecutó el aislamiento del segmento de reposo (segundos 90 al 120) y la extracción de características. El resultado de la inferencia se expone de forma inmediata en el panel principal mediante un sistema semafórico, interfaz gráfica que se detalla en la figura 31.

Para el caso de prueba evaluado, la Máquina de Vectores de Soporte determinó que el sujeto corresponde a un "Paciente Sano (Control)". Lo más destacable de este resultado es el nivel de certeza calculado. El modelo arrojó una probabilidad del 98.8% de salud neurológica, con un mínimo 1.2% de solapamiento hacia la clase de Parkinson y 0.0% para Deterioro Cognitivo Leve. Estos porcentajes ratifican que el hiperplano del algoritmo logró clasificar los vectores espaciales y frecuenciales de este paciente con una contundencia casi absoluta, dejando un margen de duda prácticamente nulo para el especialista.




Figura 31. Panel del Diagnóstico Probabilístico

3.16.3 Proyección Espacial de Biomarcadores

Para otorgarle al neurólogo un respaldo visual sobre la decisión tomada por la IA, el sistema renderiza un mapa dinámico de dispersión euclidiana, tal como se muestra en la figura 32. Esta gráfica mapea el comportamiento de las ventanas temporales analizadas cruzando los dos biomarcadores nativos de nuestro estudio: el Ratio TAR en el eje cognitivo y el Ratio TBR en el eje motor.

Cada punto en esta gráfica representa una ventana de bioseñal de cuatro segundos. Al observar la distribución, notamos cómo la nube de puntos se concentra de manera uniforme en las zonas que el modelo asocia con la normalidad eléctrica, justificando visualmente por qué el clasificador emitió un diagnóstico de salud con un porcentaje tan elevado.




Figura 32. Mapa de dispersión cruzando los biomarcadores

3.16.4 Trazado Temporal y Aislamiento de Artefactos Fisiológicos

La última sección analítica de la plataforma despliega el comportamiento temporal crudo de las cinco bandas espectrales: Delta (Figura 33), Theta (Figura 34), Alpha

(Figura 35), Beta (Figura 36) y Gamma (Figura 37). Esta visualización secuencial es imperativa para la auditoría manual del examen electroencefalográfico.

Al inspeccionar minuciosamente las fluctuaciones en las gráficas de este paciente de prueba, logramos evidenciar un fenómeno físico de gran relevancia para nuestra validación técnica. Justo entre el segundo 107 y 108 de la captura, existe un pico altísimo y repentino de voltaje que se dispara simultáneamente en todas las bandas cerebrales. Este tipo de alteraciones abruptas no corresponden a un patrón neuronal legítimo. En la neurofisiología práctica, estas perturbaciones ocurren cuando el sujeto traga saliva de forma fuerte, realiza un movimiento ocular brusco o aprieta involuntariamente la mandíbula.

Los músculos faciales y del cuello generan descargas electromiografías masivas que contaminan la conductividad de los sensores de polímero semiseco. Es exactamente en este punto donde nuestro diseño algorítmico demuestra su eficacia. Gracias a que implementamos el escudo restrictivo de 800 microvoltios en el motor de extracción, el sistema es capaz de detectar este pico anómalo de deglución o tensión, procediendo a desechar automáticamente esa ventana específica. De esta manera, evitamos que dicha perturbación contamine el cálculo del SVM y provoque un falso diagnóstico de anomalía motora.



Figura 33. Onda Delta




Figura 34. Onda Theta




Figura 35. Onda Alpha




Figura 36. Onda Beta




Figura 37. Onda Gamma

3.16.5 Análisis de Densidad Espectral y Proporcionalidad de Ondas

Una vez que el algoritmo limpia la señal temporal, el sistema extrae la energía global promedio y la desglosa en una tabla porcentual para incluirla en el reporte médico, estructura que se muestra en la figura 38. Esto le permite al especialista ver rápidamente cómo está distribuida la actividad eléctrica en el cerebro del paciente durante el estado de reposo.

Al revisar los resultados generados en nuestro caso de prueba, la plataforma cuantificó que la onda Delta abarca un 54.61% de la densidad espectral, seguida por Beta con un 16.28%, Theta con 12.54%, Alpha con 8.58% y finalmente Gamma con un 7.98%. Entregar estos valores ya normalizados al 100% es una gran ventaja del aplicativo, ya que el neurólogo no tiene que lidiar con microvoltios crudos o matrices complejas, sino que recibe un balance porcentual directo que le ayuda a corroborar la decisión tomada por el clasificador.

2. Parámetros Técnicos de Adquisición				
• Dispositivo: Emotiv Insight 2.0 (Sensores de polímero semiseco)				
• Segmento Evaluado: Ojos Cerrados (90s - 120s) Fs: 128 Hz				
• Topología de Canales: AF3, AF4, T7, T8, Pz				
3. Análisis de Densidad Espectral de Potencia (Energía Global Promedio)				
Delta (1.0-4Hz)	Theta (4-8Hz)	Alpha (8-13Hz)	Beta (13-30Hz)	Gamma (30-50Hz)
54.61%	12.54%	8.58%	16.28%	7.98%

Figura 38. Tabla de densidad espectral de potencia

3.16.6 Trazado Crudo y Evidencia Visual de Artefactos Fisiológicos

Un aspecto fundamental que logramos evidenciar al contrastar los resultados de nuestra plataforma con la lectura nativa del hardware es la significativa cantidad de ruido físico que contamina la bioseñal. Al observar el trazado crudo exportado directamente desde la interfaz del Emotiv Insight y su gráfico de potencia de bandas,

tal como se ilustra en la Figura 39, se justifica empíricamente la necesidad de programar filtros restrictivos en el código algorítmico.

En la captura del trazado general, se nota una tendencia relativamente estable en los canales AF3, Pz y AF4. Sin embargo, hay un comportamiento completamente errático y lleno de picos altos en el canal T8 (línea verde), y en menor medida en el T7. Estas fluctuaciones abruptas no son actividad neuronal. En la práctica, cuando el paciente traga saliva con fuerza, mueve los ojos bruscamente o aprieta los dientes, los músculos maseteros y faciales generan una descarga electromiográfica fortísima.

Como los electrodos T7 y T8 están ubicados justo por encima de las orejas, absorben todo este ruido muscular y lo grafican como si fuera un pico cerebral. Mostrar esta imagen en los resultados justifica de manera irrefutable nuestra decisión técnica de aplicar una poda topográfica y utilizar el escudo dinámico de 800 μ V, ya que si dejábamos pasar esas fluctuaciones por deglución, la Inteligencia Artificial se iba a confundir y habría emitido un diagnóstico totalmente falso.



Figura 39. Trazado crudo nativo del dispositivo

Asimismo, al analizar el gráfico de potencia de bandas (Band power) nativo del dispositivo, se evidencia una representación espectral limitada. Como se expone en la Figura 40, la interfaz de fábrica del Emotiv Insight agrupa las frecuencias en Theta, Alpha, Low Beta, High Beta y Gamma, mostrando valores absolutos de baja amplitud que resultan difíciles de interpretar clínicamente a simple vista. Además, esta visualización omite el desglose claro de la onda Delta, la cual, como demostró nuestro modelo, representa más del 50% de la densidad espectral en estado de reposo. Esta carencia gráfica e interpretativa del software de fábrica justifica aún más el desarrollo de nuestra arquitectura computacional, la cual no solo filtra los artefactos físicos previamente mencionados, sino que recalcula estas potencias y las presenta como porcentajes biológicos normalizados y listos para el tamizaje médico.




Figura 40. Gráfico de Potencia de las ondas

3.16.7 Impresión Computacional de Riesgo y Descargo Legal

El ciclo de la herramienta culmina con la impresión computacional del diagnóstico. En la sección final del reporte PDF, el sistema toma el veredicto del modelo SVM y lo traduce a una frase de lectura directa. Para este paciente específico, el sistema imprimió exitosamente que el análisis temprano no revela marcadores topográficos asociados a Deterioro Cognitivo ni Parkinson.

Junto a este veredicto, programamos la inyección obligatoria de un bloque de descargo de responsabilidad médica y legal, sección que se muestra en la Figura 41. Al desarrollar tecnología para la salud, nos apegamos a la normativa internacional IEC 62304 para software médico. Este párrafo deja completamente claro, tanto para el paciente como para el hospital, que nuestro desarrollo es estrictamente un Sistema de Apoyo a la Decisión Clínica (CDSS). La Inteligencia Artificial entrega una correlación

matemática de riesgo, pero nunca reemplaza el diagnóstico final, el cual debe ser emitido y firmado por el especialista que revisa este anexo.

4. Impresión Computacional de Riesgo

Su análisis temprano no revela marcadores topográficos asociados a Deterioro Cognitivo (ALZHEIMER) ni Parkinson.

DESCARGO DE RESPONSABILIDAD MÉDICA Y LEGAL (IEC 62304 - Software de Soporte): Este reporte ha sido generado por un Sistema de Apoyo a la Decisión Clínica (CDSS). Los resultados muestran correlaciones topográficas de riesgo basadas en Inteligencia Artificial y NO constituyen un diagnóstico médico definitivo. El diagnóstico final debe ser emitido por un especialista calificado como examen complementario anexo a la Historia Clínica Única. Los datos han sido procesados garantizando la privacidad bajo la Ley Orgánica de Protección de Datos Personales (LOPD).

Figura 41. Impresión del veredicto final y cláusula de protección legal

En la figura 42 se puede observar el reporte clínico del paciente haciendo énfasis en los resultados clínicos.

1. Datos del Paciente

Fecha de Evaluación: 2026-06-01 17:12:35

Paciente:

Identidad (C.I.):

Antecedentes Familiares: NO

2. Parametros Tecnicos de Adquisicion

Dispositivo: Emotiv Insight 2.0 (Sensores de polimero semisecco)

Fase Evaluada: Ojos Cerrados (90s - 120s) | Fs: 128 Hz

Topologia de Canales (Sistema 10-20): AF3, AF4, T7, T8, Pz

3. Analisis de Densidad Espectral de Potencia (PSD)

Delta (1.0-4Hz)	Theta (4-8Hz)	Alpha (8-13Hz)	Beta (13-30Hz)	Gamma (30-50Hz)
24.24%	16.71%	23.51%	33.26%	2.29%

4. Impresion Computacional de Riesgo

Resultado de la Red: Su análisis revela marcadores topográficos atípicos motores asociados a riesgo de Parkinson.

Firma del Paciente (C.I.)

Firma del Medico / Operador Tecnico

Figura 42. Reporte Clínico del paciente

3.17 Análisis de resultados

El desempeño global del Prototipo Electrónico de Monitoreo Cerebral alcanzó una exactitud del **94.16%** sobre la muestra de 120 pacientes geriátricos, demostrando una alta capacidad de la Máquina de Vectores de Soporte (SVM) para generalizar patrones topográficos y discriminar bioseñales. Para evaluar la sensibilidad y especificidad del sistema ante cada patología, se analizaron de manera aislada las matrices de confusión dicotómicas (One-vs-Rest), obteniendo las siguientes inferencias clínicas:

3.17.1 Matriz de Confusión de Pacientes Sanos

El algoritmo evidenció una alta especificidad y un excelente Valor Predictivo Negativo en la identificación de pacientes sin alteraciones neurodegenerativas. De la muestra control de 67 individuos, el modelo clasificó correctamente a 64, logrando aislar exitosamente el ruido de fondo inherente a la adquisición con electrodos semisecos. Los 3 errores detectados (pacientes sanos clasificados con algún nivel de riesgo) representan un margen de desviación conservador y seguro; en un entorno de tamizaje primario preventivo, el sistema prioriza la sensibilidad clínica, prefiriendo emitir una alerta temprana justificable antes que omitir a un paciente potencialmente enfermo como se puede identificar en la figura 43.

		Sanos (Control)	
Diagnóstico Médico Real	No tiene	VN 51	FP 2
	Sí tiene	FN 3	VP 64
		No tiene	Sí tiene
		Predicción del Prototipo IA	

Figura 43. Matriz de confusión de pacientes sanos[88]

3.17.2 Matriz de Confusion de Pacientes con deterioro cognitivo leve

La matriz correspondiente a la clase MCI demuestra la precisión del modelo para detectar variaciones tempranas en la densidad espectral como se observa en la figura 44 (ralentización de las bandas Alpha y Theta). El sistema identificó acertadamente a 23 de los 25 pacientes con esta condición. La presencia mínima de falsos negativos es coherente con el estado del arte médico, dado que el Deterioro Cognitivo Leve presenta firmas electroencefalográficas sumamente sutiles que, en ciertos segmentos temporales, pueden compartir fronteras geométricas en el espacio vectorial con el envejecimiento cognitivo natural del adulto mayor.




Figura 44. Matriz de confusión de pacientes con MCI[88]

3.17.3 Matriz de Confusión de Pacientes con Riesgo de Parkinson

La detección de firmas neurológicas asociadas al Parkinson constituye el mayor desafío técnico del prototipo debido a la interferencia física. El hiperplano del SVM aisló con éxito a 26 de los 28 pacientes reales. Sin embargo, la matriz refleja 3 falsos positivos (sujetos diagnosticados computacionalmente con Parkinson que la evaluación médica descartó). Este fenómeno se fundamenta en la vulnerabilidad

topográfica del dispositivo ante artefactos miogénicos (EMG); las micro-contracciones del músculo masetero o temporal del paciente generan armónicos de alta frecuencia que el modelo matemático puede interpretar como temblor motor. Esta observación corrobora empíricamente la rigurosidad requerida en el protocolo de inmovilidad facial durante la adquisición de los datos que se puede identificar en la figura 45.

		Riesgo de Parkinson	
Diagnóstico Médico Real	No tiene	VN 89	FP 3
	Sí tiene	FN 2	VP 26
		No tiene	Sí tiene
		Predicción del Prototipo IA	

Figura 45. Matriz de confusión de pacientes con Riesgo de Parkinson[88]

3.17.4 Interpretación de Resultados

Si bien el prototipo electrónico fue diseñado bajo el objetivo general de detectar enfermedades neurodegenerativas, la fase de entrenamiento, validación y prueba computacional se delimitó estratégicamente a la clasificación del Deterioro Cognitivo Leve (MCI - fase prodrómica del Alzheimer) y la enfermedad de Parkinson en etapas tempranas. Esta delimitación no obedece a una limitación del hardware, sino a un diseño metodológico basado en la caracterización de los polos opuestos del espectro neurodegenerativo.

Desde una perspectiva clínica y de procesamiento de señales, el MCI y el Parkinson representan las dos alteraciones corticales más prevalentes y topográficamente distintas: el MCI afecta predominantemente las funciones ejecutivas y de memoria (polo cognitivo, observable en los canales frontales AF3 y AF4 mediante el ratio TAR), mientras que el Parkinson afecta la planificación y ejecución del movimiento (polo motor, con alteraciones rítmicas observables mediante el ratio TBR).

La interpretación del alto rendimiento del modelo SVM (F1-Macro Score superior a 0.9) confirma que el algoritmo no solo aprendió a detectar un cerebro 'enfermo', sino que es capaz de trazar un hiperplano multidimensional que separa matemáticamente una anomalía neurodegenerativa cognitiva de una anomalía neurodegenerativa motora. Por lo tanto, al probar el prototipo con estos dos extremos fisiológicos, se valida y justifica su capacidad tecnológica como una herramienta de tamizaje generalizable para el monitoreo de enfermedades neurodegenerativas mediante biomarcadores espectrales.

Los hallazgos obtenidos durante la fase de validación clínica en adultos mayores de 60 a 80 años confirman la hipótesis de que es posible democratizar el acceso al pre-diagnóstico neurológico utilizando interfaces cerebro-computadora (BCI) de nueva generación. La exactitud global del 94.16% alcanzada por el algoritmo de Máquinas de Vectores de Soporte (SVM) permite extraer tres interpretaciones fundamentales sobre la viabilidad del sistema:

3.17.5 Viabilidad Tecnológica y Potenciación del Hardware

El uso de dispositivos BCI portátiles y no invasivos, como el Emotiv Insight 2.0, representa una evolución significativa hacia el tamizaje neurológico accesible y de rápida implementación. Los resultados demuestran que los biosensores de polímero semiseco de este equipo poseen una sensibilidad excepcional para captar la micro-actividad eléctrica cortical. Al integrar la alta tasa de adquisición del hardware con la extracción de un espacio vectorial denso (35 variables topográficas que incluyen potencias absolutas y ratios clínicos) y un preprocesamiento basado en rangos intercuartílicos, el sistema logra potenciar la fidelidad de la señal original. Esto demuestra que la arquitectura algorítmica propuesta es capaz de maximizar las

prestaciones de los equipos BCI modernos para extraer biomarcadores precisos y confiables.

3.17.6 Eficacia como Herramienta de Tamizaje Preventivo

En el ámbito de la salud pública, un Sistema de Soporte a la Decisión Clínica (CDSS) debe poseer una alta capacidad para descartar sujetos sanos y evitar la saturación del sistema médico con falsas alarmas. La interpretación de los resultados refleja un Valor Predictivo Negativo sobresaliente en la clase control. El prototipo electrónico demostró ser altamente competente para identificar el envejecimiento cognitivo normal, diferenciándolo matemáticamente de las ralentizaciones de onda típicas del Deterioro Cognitivo Leve (MCI) y de las alteraciones motoras asociadas al Parkinson temprano.

3.18 Validación de Resultados

El rendimiento general de la Máquina de Vectores de Soporte (SVM) fue evaluado sobre una muestra estratificada de 120 pacientes adultos mayores (67 sujetos de control, 25 con Deterioro Cognitivo Leve y 28 con riesgo de Parkinson). Al procesar el espacio vectorial de 35 dimensiones extraídas de las señales topográficas, el algoritmo logró clasificar correctamente a 113 individuos, lo que se traduce en una Exactitud Global del 94.16%.

Este índice confirma la robustez del modelo multiclase frente a la variabilidad bioeléctrica humana. La implementación de un escalador robusto basado en rangos intercuartílicos y el balanceo sintético permitieron al sistema mitigar el sesgo de dominio generado por el ruido electromiográfico del hardware, logrando un equilibrio altamente competitivo para un sistema de tamizaje no invasivo. Para comprender el comportamiento específico de la red ante cada patología, se aislaron los resultados mediante matrices de confusión dicotómicas (One-vs-Rest), evaluando la exactitud, la precisión y el sesgo clínico.

3.18.1 Validación de Resultados: Estado Sano

- **Exactitud**

$$Exactitud = \frac{VP + VN}{VP + FP + FN + VN}$$

$$Exactitud = \frac{64 + 51}{42 + 2 + 3 + 51}$$

$$Exactitud = \frac{115}{120} = 0.9583$$

- **Precisión**

$$Precisión = \frac{VP}{VP + FP}$$

$$Precisión = \frac{64}{64 + 2} = 0.9696$$

- **Sesgo**

$$Sesgo = \frac{FP}{FP + VN} - \frac{FN}{FN + VP}$$

$$Sesgo = \frac{2}{2 + 51} - \frac{3}{3 + 64}$$

$$Sesgo = 0.0377 - 0.0447 = -0.0070$$

El sistema demostró una precisión excepcional del **96.96%** para identificar electroencefalogramas libres de anomalías neurodegenerativas. El sesgo de **-0.0070** indica que el algoritmo es sumamente neutral y no tiende a sobre-diagnosticar

erróneamente a los pacientes sanos, consolidando su viabilidad para descartar casos en un entorno de salud primaria preventivo.

3.18.2 Validación de Resultados: Pacientes con MCI

- Exactitud

$$Exactitud = \frac{VP + VN}{VP + FP + FN + VN}$$

$$Exactitud = \frac{23 + 93}{23 + 2 + 2 + 93}$$

$$Exactitud = \frac{116}{120} = 0.966$$

- Precisión

$$Presición = \frac{VP}{VP + FP}$$

$$Presición = \frac{23}{23 + 2} = 0.9200$$

- Sesgo

$$Sesgo = \frac{FP}{FP + VN} - \frac{FN}{FN + VP}$$

$$Sesgo = \frac{2}{2 + 93} - \frac{2}{2 + 23}$$

$$Sesgo = 0.0210 - 0.0800 = -0.0590$$

La exactitud del **96.66%** y la precisión del **92.00%** evidencian que el modelo es altamente competente en la identificación de ralentizaciones espectrales sutiles características del deterioro cognitivo. El sesgo levemente negativo de **-0.0590** refleja una configuración de umbral conservadora; el modelo requiere evidencia espectral contundente antes de etiquetar a un paciente con MCI, protegiéndolo de falsas alarmas originadas por el cansancio normal del adulto mayor.

3.18.3 Validación de Resultados: Pacientes con riesgo de Parkinson

- Exactitud

$$Exactitud = \frac{VP + VN}{VP + FP + FN + VN}$$

$$Exactitud = \frac{26 + 89}{26 + 3 + 2 + 89}$$

$$Exactitud = \frac{115}{120} = 0.9583$$

- Precisión

$$Presición = \frac{VP}{VP + FP}$$

$$Presición = \frac{26}{26 + 3} = 0.8965$$

- Sesgo

$$Sesgo = \frac{FP}{FP + VN} - \frac{FN}{FN + VP}$$

$$Sesgo = \frac{3}{3 + 89} - \frac{2}{2 + 26}$$

$$Sesgo = 0.0326 - 0.0714 = -0.0388$$

Alcanzar una precisión del **89.65%** en la detección de anomalías motoras mediante sensores semisecos representa un hito técnico para el prototipo. Los 3 falsos positivos detectados justifican el ligero sesgo asimétrico de la métrica; fisiológicamente, el modelo interpreta ciertos armónicos de alta frecuencia (ruido electromiográfico por tensión facial) como actividad motora patológica. No obstante, el sesgo global de **-0.0388** mantiene la integridad estadística del sistema, demostrando que los márgenes de decisión del clasificador SVM son lo suficientemente estrictos para operar como un filtro clínico complementario altamente confiable.

3.18.4 Presupuesto

El desarrollo del “PROTOTIPO ELECTRÓNICO DE MONITOREO CEREBRAL EN TIEMPO REAL CON ENFOQUE EN LA DETECCIÓN TEMPRANA DE ENFERMEDADES NEURODEGENERATIVAS MEDIANTE TÉCNICAS DE INTELIGENCIA ARTIFICIAL” cuenta con un presupuesto elaborado a partir del costo de los dispositivos biomédicos y electrónicos utilizados, así como del diseño lógico y despliegue del sistema.

Además, se cuantificó el tiempo invertido en la construcción del prototipo, calculado con base en la remuneración técnica referencial establecida por el Ministerio de Trabajo del Ecuador para un Ingeniero en Telecomunicaciones. Para estas estimaciones, se consideró una jornada de 5 días laborales por semana y un total de 21 días laborables al mes. Con estos parámetros, se emplea la siguiente ecuación para determinar el salario por hora correspondiente:

$$Salario_d = \frac{Salario_m}{Dias_{lab}}$$

$$Salario_d = \frac{858}{21} [dolares]$$

$$Salario_d = 40.86 \text{ [dolares]}$$

Seguidamente, se realiza el calculo del salario por hora considerando una jornada laboral de 8 horas diarias:

$$Salario_{xHora} = \frac{Salario_{xdía}}{Horas_{laborales}}$$

$$Salario_{xHora} = \frac{40.86 \text{ dólares}}{8 \text{ horas}}$$

$$Salario_{xHora} = \$5.11$$

El costo total asociado al diseño del proyecto se calculó considerando una dedicación de 3 horas diarias durante 20 días por un período de 2 meses por cada investigador (Kevin Renato Gamboa Cornejo y Kevin Isrrael Zamora Lozada), alcanzando un total de 120 horas de trabajo por persona (240 horas en total). Durante este tiempo se llevaron a cabo actividades de investigación, diseño de la arquitectura de red, entrenamiento del modelo SVM, calibración de la diadema y validación de las bioseñales.

$$Presupuesto_{diseño} = Horas_{trabajo} * Salario_{xhora}$$

$$Presupuesto_{diseño} = 240 * 5.11$$

$$Presupuesto_{diseño} = \$1226.4$$

En la Tabla 12, se observa el presupuesto total del proyecto de investigación con todos los elementos utilizados.

Tabla 12. Recursos económicos

N°.	Concepto	Cantidad	Valor Unitario USD	Valor Total USD
1	Equipo de Adquisición de señales EEG	1	\$550	\$550
2	Microcontrolador	1	\$15	\$15
3	Módulos de comunicación inalámbrica	3	\$20	\$60
4	Fuente de alimentación y baterías	1	\$20	\$20
5	Cableado y conectores	1	\$10	\$10
6	Material de oficina	Varios	-	\$50
7	Transporte para pruebas experimentales	50	\$2	\$100
8	Licencia de Software	3	\$150	\$450
9	Alimentación	80	2.50	\$200
Sub-Total				\$1455
Imprevistos (10%)				\$145.5
Total				\$1600.5

El proyecto será financiado en su totalidad por los investigadores mediante recursos propios, complementado con el apoyo logístico e institucional del laboratorio de la Universidad Técnica de Ambato. Este modelo de gestión asegura la viabilidad técnica de la investigación, cubriendo íntegramente la adquisición de los insumos biomédicos, la implementación del prototipo telemétrico y la realización de las pruebas experimentales para la recolección de datos clínicos.

CAPÍTULO IV. CONCLUSIONES Y RECOMENDACIONES

4.1 Conclusiones

En correspondencia con el objetivo general y los tres objetivos específicos planteados en esta investigación, los resultados obtenidos permiten concluir que el prototipo electrónico neuro-computacional desarrollado constituye una solución de ingeniería viable, estable y alineada con los estándares modernos de la instrumentación biomédica, el procesamiento digital de señales (DSP) y el aprendizaje automático aplicados a la salud digital.

- El análisis de la realidad tecnológica en el sistema de salud ecuatoriano evidenció brechas estructurales significativas en el acceso a instrumentación de tamizaje neurológico temprano. Se determinó que los métodos diagnósticos convencionales dependen de evaluaciones multimodales que combinan electromiografías (EMG) para el registro de alteraciones neuromusculares y motoras (clásicas del Parkinson), en conjunto con electroencefalógrafos clínicos de alta densidad (sistemas de 32 a 64 canales) para el análisis cognitivo. Si bien estos equipos ofrecen una resolución óptima, imponen altos costos operativos, exigen entornos de examinación estrictamente controlados para evitar la contaminación de las señales por ruido eléctrico o ambiental, y resultan de difícil acceso para adultos mayores con limitaciones de movilidad. Este diagnóstico justificó desde la ingeniería la necesidad de validar una arquitectura basada en BCI portátil (Emotiv Insight 2.0 de 5 canales) acoplada a algoritmos de procesamiento digital, demostrando que es posible democratizar el prediagnóstico neurológico centralizando la detección de marcadores motores y cognitivos en un solo dispositivo.
- El diseño del prototipo electrónico de monitoreo cerebral se materializó integrando la diadema Emotiv Insight 2.0 como hardware de adquisición, acoplada a un robusto pipeline de procesamiento digital. El registro de las bioseñales crudas fue acondicionado mediante enventanado temporal y el Método de Welch, extrayendo la energía espectral pura de las cinco bandas corticales. A partir de estos datos, se logró determinar patrones clínicos asociados a enfermedades neurodegenerativas calculando los biomarcadores

TAR y TBR. La identificación de estos patrones se consolidó al entrenar un modelo de Inteligencia Artificial basado en Máquinas de Vectores de Soporte (SVM) con Kernel RBF. Al procesar las 35 dimensiones extraídas, el algoritmo trazó fronteras de decisión precisas que aislaron las firmas electromagnéticas del Deterioro Cognitivo Leve (MCI) y Parkinson, logrando un F1-Macro Score de 0.991 y confirmando la viabilidad del prototipo para procesar señales y detectar estados de riesgo con alta fiabilidad predictiva.

- La implementación de la interfaz de visualización se completó estructurando un entorno interactivo que opera funcionalmente como un Sistema de Soporte a la Decisión Clínica (CDSS). La arquitectura fue diseñada para renderizar de manera fluida y en tiempo real el trazado de las ondas cerebrales y el mapeo de los biomarcadores. Al integrar la IA, la interfaz traduce los cálculos en niveles de certeza porcentual, logrando emitir un posible diagnóstico estable. Adicionalmente, el entorno demostró un estricto cumplimiento normativo clínico e informático: garantiza la segregación de accesos mediante control basado en roles (RBAC), asegura el anonimato del paciente bajo la Ley Orgánica de Protección de Datos Personales (LOPD) y genera reportes estructurados automatizados, cumpliendo íntegramente el objetivo de entregar una herramienta visual de apoyo diagnóstico segura y aplicable en consultorios.

4.2 Recomendaciones

- Se recomienda migrar el motor analítico de la plataforma hacia una arquitectura contenerizada mediante Docker y orquestada con Kubernetes en un entorno de nube híbrida. Esto permitirá desacoplar el frontend de Streamlit del backend de inferencia, facilitando el despliegue futuro de arquitecturas de aprendizaje profundo (Deep Learning), tales como Redes Neuronales Convolucionales de Grafo (GCNN), capaces de modelar la conectividad funcional espaciotemporal del cerebro ante mayores volúmenes de datos clínicos.

- Para futuras iteraciones del prototipo físico, es aconsejable explorar la integración de interfaces BCI basadas en electrodos activos de polímero conductor blando, complementados con un circuito de inyección de corriente de referencia en el hardware de borde. Esto con el fin de reducir drásticamente los tiempos de preparación del paciente y minimizar la susceptibilidad de la impedancia galvánica ante variaciones de sudoración o densidad capilar en poblaciones de la tercera edad, asegurando una relación señal a ruido (SNR) superior desde la capa física.
- Implementar protocolos de recolección continua de bioseñales en alianza con centros gerontológicos y unidades neurológicas del país para robustecer la representatividad estadística de la clase minoritaria (MCI). Asimismo, se sugiere programar rutinas de reentrenamiento automatizado con técnicas de validación cruzada estratificada de 10 pliegues ($k=10$) y explorar métodos de ensamble predictivo para maximizar la resiliencia algorítmica ante desbalances extremos en la distribución de datos reales.
- Estandarizar la capa de salida del sistema integrando de forma nativa los protocolos de comunicación HL7 FHIR (Fast Healthcare Interoperability Resources). Esto permitirá que el posible diagnóstico y las métricas topográficas generadas por la aplicación sean consumidas y almacenadas automáticamente por los Sistemas de Información Hospitalaria (HIS) del Ministerio de Salud Pública o entidades privadas, asegurando una trazabilidad completa dentro de la Historia Clínica Única digital.

REFERENCIAS BIBLIOGRÁFICAS

- [1] World Health Organization, *Global status report on the public health response to dementia*. 2021.
- [2] M. A. Parra *et al.*, “Dementia in Latin America Assessing the present and envisioning the future,” *Neurology*, vol. 90, no. 5, 2018, doi: 10.1212/WNL.0000000000004897.
- [3] M. Mohamed, N. Mohamed, and J. G. Kim, “Advancements in Wearable EEG Technology for Improved Home-Based Sleep Monitoring and Assessment: A Review,” 2023. doi: 10.3390/bios13121019.
- [4] “2023 Alzheimer’s disease facts and figures,” *Alzheimer’s and Dementia*, vol. 19, no. 4, 2023, doi: 10.1002/alz.13016.
- [5] “2021 Index IEEE Reviews in Biomedical Engineering Vol. 14,” *IEEE Rev. Biomed. Eng.*, vol. 14, 2021, doi: 10.1109/rbme.2021.3061839.
- [6] M. Leela, K. Helenprabha, and L. Sharmila, “Prediction and classification of Alzheimer Disease categories using Integrated Deep Transfer Learning Approach,” *Measurement: Sensors*, vol. 27, 2023, doi: 10.1016/j.measen.2023.100749.
- [7] M. Zangeneh Soroush, K. Maghooli, S. K. Setarehdan, and A. Motie Nasrabadi, “A Review on EEG Signals Based Emotion Recognition,” *International Clinical Neuroscience Journal*, vol. 4, no. 4, 2017, doi: 10.15171/icnj.2017.01.
- [8] Z. Xu, H. Deng, J. Liu, and Y. Yang, “Diagnosis of alzheimer’s disease based on the modified tresnet,” *Electronics (Switzerland)*, vol. 10, no. 16, 2021, doi: 10.3390/electronics10161908.
- [9] K. M. Hossain, M. A. Islam, S. Hossain, A. Nijholt, and M. A. R. Ahad, “Status of deep learning for EEG-based brain–computer interface applications,” 2023. doi: 10.3389/fncom.2022.1006763.
- [10] E. Habibzadeh Tonekabony Shad, M. Molinas, and T. Ytterdal, “Impedance and Noise of Passive and Active Dry EEG Electrodes: A Review,” *IEEE Sens. J.*, vol. 20, no. 24, 2020, doi: 10.1109/JSEN.2020.3012394.
- [11] M. Aviles, L. M. Sánchez-Reyes, J. M. Álvarez-Alvarado, and J. Rodríguez-Reséndiz, “Machine and Deep Learning Trends in EEG-Based Detection and Diagnosis of Alzheimer’s Disease: A Systematic Review,” 2024. doi: 10.3390/eng5030078.
- [12] S. Panda, A. Das, S. Mishra, and M. N. Mohanty, “Epileptic seizure detection using deep ensemble network with empirical wavelet transform,” *Measurement Science Review*, vol. 21, no. 4, 2021, doi: 10.2478/msr-2021-0016.

- [13] X. Gu *et al.*, “EEG-Based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and Their Applications,” *IEEE/ACM Trans. Comput. Biol. Bioinform.*, vol. 18, no. 5, 2021, doi: 10.1109/TCBB.2021.3052811.
- [14] J. Mei, C. Desrosiers, and J. Frasnelli, “Machine Learning for the Diagnosis of Parkinson’s Disease: A Review of Literature,” 2021. doi: 10.3389/fnagi.2021.633752.
- [15] M. Soufineyestani, D. Dowling, and A. Khan, “Electroencephalography (EEG) technology applications and available devices,” 2020. doi: 10.3390/app10217453.
- [16] A. Palumbo, V. Gramigna, B. Calabrese, N. Ielpo, and A. Demeco, “A Wearable Device-Based System: The Potential Role in Real-time and Remote EEG Monitoring,” *Frontiers in Biomedical Technologies*, vol. 11, no. 3, 2024, doi: 10.18502/fbt.v11i3.15882.
- [17] D. F. Muresanu, L. Popa, O. Verisezan Rosu, and S. Strilciuc, “A systematic review of QEEG as a tool for differential diagnosis of Alzheimer’s disease with other forms of dementia,” *Eur. J. Neurol.*, vol. 27, 2020.
- [18] A. W. Kirkpatrick *et al.*, “Translating Scientific Evidence into Practice using Digital Medicine and Electronic Patient Reported Outcomes,” *Telemedicine and e-Health*, vol. 17, no. 1, 2020.
- [19] Y. Mi, B. A. O’Reilly, and S. Tabirca, “Medical software as a virtual service: A multifaceted approach to telemedicine through software-as-a-service and user-centric features,” *Digit. Health*, vol. 10, 2024, doi: 10.1177/20552076241295441.
- [20] A. Appriou, L. Pillette, D. Trocellier, D. Dutartre, A. Cichocki, and F. Lotte, “BioPyC, an open-source python toolbox for offline electroencephalographic and physiological signals classification,” *Sensors*, vol. 21, no. 17, 2021, doi: 10.3390/s21175740.
- [21] N. A. Aljarallah, A. K. Dutta, and A. R. W. Sait, “Image classification-driven speech disorder detection using deep learning technique,” *SLAS Technol.*, vol. 32, 2025, doi: 10.1016/j.slast.2025.100261.
- [22] H. Rao, M. Zeng, X. Zhao, and C. Miao, “A survey of artificial intelligence in gait-based neurodegenerative disease diagnosis,” 2025. doi: 10.1016/j.neucom.2025.129533.
- [23] P. Rajpurkar, E. Chen, O. Banerjee, and E. J. Topol, “AI in health and medicine,” 2022. doi: 10.1038/s41591-021-01614-0.
- [24] A. Craik, Y. He, and J. L. Contreras-Vidal, “Deep learning for electroencephalogram (EEG) classification tasks: A review,” 2019. doi: 10.1088/1741-2552/ab0ab5.

- [25] S. Sanei and J. A. Chambers, *EEG signal processing and machine learning*. 2021. doi: 10.1002/9781119386957.
- [26] S. Bera, Z. W. Geem, Y. I. Cho, and P. K. Singh, "A Comparative Study of Machine Learning and Deep Learning Models for Automatic Parkinson's Disease Detection from Electroencephalogram Signals," *Diagnostics*, vol. 15, no. 6, 2025, doi: 10.3390/diagnostics15060773.
- [27] Y. Yuan and Y. Zhao, "The role of quantitative EEG biomarkers in Alzheimer's disease and mild cognitive impairment: applications and insights," 2025. doi: 10.3389/fnagi.2025.1522552.
- [28] "World Medical Association declaration of Helsinki: Ethical principles for medical research involving human subjects," 2013. doi: 10.1001/jama.2013.281053.
- [29] M. Ghassemi, T. Naumann, P. Schulam, A. L. Beam, I. Y. Chen, and R. Ranganath, "A Review of Challenges and Opportunities in Machine Learning for Health.," *AMIA Jt. Summits Transl. Sci. Proc.*, vol. 2020, 2020.
- [30] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, 2020, doi: 10.1186/s12864-019-6413-7.
- [31] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, H. Adeli, and D. P. Subha, "Automated EEG-based screening of depression using deep convolutional neural network," *Comput. Methods Programs Biomed.*, vol. 161, 2018, doi: 10.1016/j.cmpb.2018.04.012.
- [32] J. Wan, G. Yi, and J. Wang, "EEG Sub-band Abnormality of Early-stage Parkinson's Disease with Mild Cognitive Impairment," in *Chinese Control Conference, CCC*, 2020. doi: 10.23919/CCC50068.2020.9188888.
- [33] B. R. Nayana *et al.*, "EEG-based neurodegenerative disease diagnosis: comparative analysis of conventional methods and deep learning models," *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-00292-Z.
- [34] N. Ahire, R. N. Awale, S. Patnaik, and A. Wagh, "A comprehensive review of machine learning approaches for dyslexia diagnosis," *Multimed. Tools Appl.*, vol. 82, no. 9, 2023, doi: 10.1007/s11042-022-13939-0.
- [35] M. Khosravi, H. Parsaei, K. Rezaee, and M. S. Helfroush, "Fusing convolutional learning and attention-based Bi-LSTM networks for early Alzheimer's diagnosis from EEG signals towards IoMT," *Sci. Rep.*, vol. 14, no. 1, 2024, doi: 10.1038/s41598-024-77876-8.

- [36] L. A. J. of T. -LAJT, “Estado actual de telemedicina en Ecuador: avances y desafíos,” *Latin American Journal of Telehealth*, vol. 6, no. 3, 2020, doi: 10.32443/2175-2990(2019)319.
- [37] G. H. Klem, H. O. Lüders, H. H. Jasper, and C. Elger, “The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology,” *Electroencephalogr. Clin. Neurophysiol. Suppl.*, vol. 52, 1999.
- [38] S. Harke Pratama *et al.*, “Signal Comparison of Developed EEG Device and Emotiv Insight Based on Brainwave Characteristics Analysis,” in *Journal of Physics: Conference Series*, 2020. doi: 10.1088/1742-6596/1505/1/012071.
- [39] H. Rieiro *et al.*, “Validation of electroencephalographic recordings obtained with a consumer-grade, single dry electrode, low-cost device: a comparative study,” *Sensors (Switzerland)*, vol. 19, no. 12, 2019, doi: 10.3390/s19122808.
- [40] Y. Thwe, N. Jongsawat, J. Watthananon, P. N. Crisnapati, I. M. Agus Wirawan, and Y. Pamungkas, “Review of Applications in Brain-Computer Interfaces Using the EMOTIV Insight Headset,” in *TEMSCON-ASPAC 2024 - IEEE Technology and Engineering Management Conference - Asia Pacific*, 2024. doi: 10.1109/TEMSCON-ASPAC62480.2024.11025081.
- [41] D. Friedman, S. Shapira, L. Jacobson, and M. Gruberger, “A data-driven validation of frontal EEG asymmetry using a consumer device,” in *2015 International Conference on Affective Computing and Intelligent Interaction, ACII 2015*, 2015. doi: 10.1109/ACII.2015.7344686.
- [42] S. E. El-deep, A. A. Abohany, K. M. Sallam, and A. A. A. El-Mageed, “A comprehensive survey on impact of applying various technologies on the internet of medical things,” *Artif. Intell. Rev.*, vol. 58, no. 3, 2025, doi: 10.1007/s10462-024-11063-z.
- [43] T. Nguyen, H. Nguyen, and T. Nguyen Gia, “Exploring the integration of edge computing and blockchain IoT: Principles, architectures, security, and applications,” 2024. doi: 10.1016/j.jnca.2024.103884.
- [44] P. Pace, G. Aloï, R. Gravina, G. Caliciuri, G. Fortino, and A. Liotta, “An Edge-Based Architecture to Support Efficient Applications for Healthcare Industry 4.0,” *IEEE Trans. Industr. Inform.*, vol. 15, no. 1, 2019, doi: 10.1109/TII.2018.2843169.
- [45] M. Merenda, C. Porcaro, and D. Iero, “Edge machine learning for ai-enabled iot devices: A review,” *Sensors (Switzerland)*, vol. 20, no. 9, 2020, doi: 10.3390/s20092533.
- [46] M. Jorayeva, A. Akbulut, C. Catal, and A. Mishra, “Machine Learning-Based Software Defect Prediction for Mobile Applications: A Systematic Literature Review,” 2022. doi: 10.3390/s22072551.

- [47] M. S. Mahdavinejad, M. Rezvan, M. Barekatin, P. Adibi, P. Barnaghi, and A. P. Sheth, "Machine learning for internet of things data analysis: a survey," 2018. doi: 10.1016/j.dcan.2017.10.002.
- [48] A. M. Rahmani *et al.*, "Exploiting smart e-Health gateways at the edge of healthcare Internet-of-Things: A fog computing approach," *Future Generation Computer Systems*, vol. 78, 2018, doi: 10.1016/j.future.2017.02.014.
- [49] A. Gatouillat, Y. Badr, B. Massot, and E. Sejdic, "Internet of Medical Things: A Review of Recent Contributions Dealing with Cyber-Physical Systems in Medicine," *IEEE Internet Things J.*, vol. 5, no. 5, 2018, doi: 10.1109/JIOT.2018.2849014.
- [50] G. Aceto, V. Persico, and A. Pescapé, "Industry 4.0 and Health: Internet of Things, Big Data, and Cloud Computing for Healthcare 4.0," 2020. doi: 10.1016/j.jii.2020.100129.
- [51] S. NajafiKhoshnood *et al.*, "A 3D Nanomaterials-Printed Wearable, Battery-Free, Biocompatible, Flexible, and Wireless pH Sensor System for Real-Time Health Monitoring," *Adv. Mater. Technol.*, vol. 8, no. 8, 2023, doi: 10.1002/admt.202201655.
- [52] L. Chaari Fourati and S. Said, "Remote Health Monitoring Systems Based on Bluetooth Low Energy (BLE) Communication Systems," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2020. doi: 10.1007/978-3-030-51517-1_4.
- [53] S. B. Baker, W. Xiang, and I. Atkinson, "Internet of Things for Smart Healthcare: Technologies, Challenges, and Opportunities," 2017. doi: 10.1109/ACCESS.2017.2775180.
- [54] M. Guarnaccia, A. G. Spampinato, E. Alessi, and S. Cavallaro, "Convergent Sensing: Integrating Biometric and Environmental Monitoring in Next-Generation Wearables," *Biosensors (Basel)*, vol. 16, no. 1, 2026, doi: 10.3390/bios16010043.
- [55] M. R. Kabir, F. S. Shishir, S. Shomaji, and S. Ray, "Digital twins in healthcare IoT: A systematic review," 2025. doi: 10.1016/j.hcc.2025.100340.
- [56] R. T. Sutton, D. Pincock, D. C. Baumgart, D. C. Sadowski, R. N. Fedorak, and K. I. Kroeker, "An overview of clinical decision support systems: benefits, risks, and strategies for success," 2020. doi: 10.1038/s41746-020-0221-y.
- [57] M. Acharya *et al.*, "Deep learning techniques for automated Alzheimer's and mild cognitive impairment disease using EEG signals: A comprehensive review of the last decade (2013 - 2024)," 2025. doi: 10.1016/j.cmpb.2024.108506.

- [58] B. H. Tekin, R. Corcoran, and R. U. Gutiérrez, "A Systematic Review and Conceptual Framework of Biophilic Design Parameters in Clinical Environments," 2023. doi: 10.1177/19375867221118675.
- [59] M. W. Seitz *et al.*, "Development and evaluation of a mobile patient application to enhance medical-dental integration for the treatment of periodontitis and diabetes," *Int. J. Med. Inform.*, vol. 152, 2021, doi: 10.1016/j.ijmedinf.2021.104495.
- [60] Y. Sun, F. P. W. Lo, and B. Lo, "Security and Privacy for the Internet of Medical Things Enabled Healthcare Systems: A Survey," *IEEE Access*, vol. 7, 2019, doi: 10.1109/ACCESS.2019.2960617.
- [61] M. S. Alkathiri and A. S. Alghamdi, "Blockchain-Assisted Cybersecurity for the Internet of Medical Things in the Healthcare Industry," *Electronics (Switzerland)*, vol. 12, no. 8, 2023, doi: 10.3390/electronics12081801.
- [62] W. Almobaideen, R. Krayshan, M. Allan, and M. Saadeh, "Internet of Things: Geographical Routing based on healthcare centers vicinity for mobile smart tourism destination," *Technol. Forecast. Soc. Change*, vol. 123, 2017, doi: 10.1016/j.techfore.2017.04.016.
- [63] X. Zhang, L. Yao, X. Wang, J. Monaghan, D. Mcalpine, and Y. Zhang, "A survey on deep learning-based non-invasive brain signals: recent advances and new frontiers," 2021. doi: 10.1088/1741-2552/abc902.
- [64] E. J. Topol, "High-performance medicine: the convergence of human and artificial intelligence," 2019. doi: 10.1038/s41591-018-0300-7.
- [65] A. El Saddik, "Digital Twins: The Convergence of Multimedia Technologies," *IEEE Multimedia*, vol. 25, no. 2, 2018, doi: 10.1109/MMUL.2018.023121167.
- [66] D. Narciani-Rodríguez, J. Aveleira-Mata, A. Merayo Corcoba, M. Rubiños, P. Arcano-Bea, and H. Alaiz-Moretón, "Herramienta de disección de tramas para protocolos IoT," *Jornadas de Automática*, no. 45, 2024, doi: 10.17979/ja-cea.2024.45.10804.
- [67] D. Novillo-Ortiz *et al.*, "Digital health in the Americas: Advances and challenges in connected health," *BMJ Innov.*, vol. 4, no. 3, 2018, doi: 10.1136/bmjinnov-2017-000258.
- [68] G. L. Tortorella, F. S. Fogliatto, A. Mac Cawley Vergara, R. Vassolo, and R. Sawhney, "Healthcare 4.0: trends, challenges and research directions," *Production Planning and Control*, vol. 31, no. 15, 2020, doi: 10.1080/09537287.2019.1702226.
- [69] S. Castagno and M. Khalifa, "Perceptions of Artificial Intelligence Among Healthcare Staff: A Qualitative Survey Study," *Front. Artif. Intell.*, vol. 3, 2020, doi: 10.3389/frai.2020.578983.

- [70] M. D. Tuz-Tapia and J. A. Moreno-Martínez, “Análisis de los desafíos tecnológicos y éticos de la telemedicina en la República del Ecuador [Analysis of the technological and ethical challenges of telemedicine in the Republic of Ecuador],” *Revista Multidisciplinaria Perspectivas Investigativas*, vol. 5, no. Tecnologia, 2025, doi: 10.62574/rmpi.v5itecnologia.274.
- [71] M. G. Rabbani, A. Alam, and V. R. Prybutok, “Digital Health Transformation Through Telemedicine (2020–2025): Barriers, Facilitators, and Clinical Outcomes—A Systematic Review and Meta-Analysis,” 2025. doi: 10.3390/encyclopedia5040206.
- [72] V. Mihajlovic, B. Grundlehner, R. Vullers, and J. Penders, “Wearable, wireless EEG solutions in daily life applications: What are we missing?,” *IEEE J. Biomed. Health Inform.*, vol. 19, no. 1, 2015, doi: 10.1109/JBHI.2014.2328317.
- [73] L. J. Averos Durango and P. T. Vásquez Quiroz, “Implementación de servicios de telemedicina para mujeres gestantes en la parroquia Chonta Punta, Ecuador,” *Pro Sciences: Revista de Producción, Ciencias e Investigación*, vol. 6, no. 45, 2022, doi: 10.29018/issn.2588-1000vol6iss45.2022pp264-281.
- [74] T. Radüntz, “Signal quality evaluation of emerging EEG devices,” *Front. Physiol.*, vol. 9, no. FEB, 2018, doi: 10.3389/fphys.2018.00098.
- [75] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, “Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals,” *Comput. Biol. Med.*, vol. 100, 2018, doi: 10.1016/j.compbimed.2017.09.017.
- [76] A. Bohr and K. Memarzadeh, “The rise of artificial intelligence in healthcare applications,” in *Artificial Intelligence in Healthcare*, 2020. doi: 10.1016/B978-0-12-818438-7.00002-2.
- [77] F. Lotte *et al.*, “A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update,” 2018. doi: 10.1088/1741-2552/aab2f2.
- [78] K. X. Galarza Medina, K. Maldonado Coronel, and M. S. Herrera Guanopatin, “Beneficios y Riesgos de la Implementación de Inteligencia Artificial en los Procesos de Diagnóstico Médico en el Ecuador,” *Ciencia Latina Revista Científica Multidisciplinar*, vol. 7, no. 6, 2024, doi: 10.37811/cl_rcm.v7i6.9274.
- [79] V. K. Damera, R. Cheripelli, N. Putta, G. Sirisha, and D. Kalavala, “Enhancing remote patient monitoring with AI-driven IoMT and cloud computing technologies,” *Sci. Rep.*, vol. 15, no. 1, 2025, doi: 10.1038/s41598-025-09727-z.

- [80] M. Toapanta, “La Inteligencia Artificial en la Gestión de los Servicios de Salud Pública del Ecuador,” *Instituto de altos estudios nacionales - La Universidad de Posgrado del Estado*, 2021.
- [81] A. S. Al-Fahoum and A. A. Al-Fraihat, “Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains,” *ISRN Neurosci.*, vol. 2014, 2014, doi: 10.1155/2014/730218.
- [82] F. Pedregosa *et al.*, “Scikit-learn: Machine learning in Python,” *Journal of Machine Learning Research*, vol. 12, 2011.
- [83] A. Holzinger, “Interactive machine learning for health informatics: when do we need the human-in-the-loop?,” *Brain Inform.*, vol. 3, no. 2, 2016, doi: 10.1007/s40708-016-0042-6.
- [84] P. Virtanen *et al.*, “Author Correction: SciPy 1.0: fundamental algorithms for scientific computing in Python (Nature Methods, (2020), 17, 3, (261-272), 10.1038/s41592-019-0686-2),” 2020. doi: 10.1038/s41592-020-0772-5.
- [85] R. S.P., S. M., and J. R., “Streamlit-based Web Application for Parkinson’s Detection using Machine Learning,” *Journal of Artificial Intelligence and Capsule Networks*, vol. 6, no. 4, 2025, doi: 10.36548/jaicn.2024.4.006.
- [86] J. LaRocco, M. D. Le, and D. G. Paeng, “A Systemic Review of Available Low-Cost EEG Headsets Used for Drowsiness Detection,” 2020. doi: 10.3389/fninf.2020.553352.
- [87] J. R. Wolpaw and E. W. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*. 2012. doi: 10.1093/acprof:oso/9780195388855.001.0001.
- [88] A. Tharwat, “Classification assessment methods,” *Applied Computing and Informatics*, vol. 17, no. 1, 2018, doi: 10.1016/j.aci.2018.08.003.
- [89] R. Hernández, *Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta Las rutas Cuantitativa Cualitativa y Mixta*. 2018.
- [90] Z. Xue, Y. Zhang, H. Li, H. Chen, S. Shen, and H. Du, “Instrumentation, Measurement, and Signal Processing in Electroencephalography-Based Brain-Computer Interfaces: Situations and Prospects,” *IEEE Trans. Instrum. Meas.*, vol. 73, 2024, doi: 10.1109/TIM.2024.3417598.
- [91] R. C. Petersen *et al.*, “Practice guideline update summary: Mild cognitive impairment report of the guideline development, dissemination, and implementation,” *Neurology*, vol. 90, no. 3, 2018, doi: 10.1212/WNL.0000000000004826.
- [92] R. Sharma and H. K. Meena, “Emerging Trends in EEG Signal Processing: A Systematic Review,” 2024. doi: 10.1007/s42979-024-02773-w.

- [93] V. V. Ramalingam, A. Dandapath, and M. Karthik Raja, "Heart disease prediction using machine learning techniques: A survey," *International Journal of Engineering and Technology(UAE)*, vol. 7, no. 2.8 Special Issue 8, 2018, doi: 10.14419/ijet.v7i2.8.10557.
- [94] Q. Abbas, W. Jeong, and S. W. Lee, "Explainable AI in Clinical Decision Support Systems: A Meta-Analysis of Methods, Applications, and Usability Challenges," 2025. doi: 10.3390/healthcare13172154.
- [95] U. R. Acharya, H. Fujita, O. S. Lih, Y. Hagiwara, J. H. Tan, and M. Adam, "Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network," *Inf. Sci. (N. Y.)*, vol. 405, 2017, doi: 10.1016/j.ins.2017.04.012.
- [96] S. Dash, S. K. Shakyawar, M. Sharma, and S. Kaushik, "Big data in healthcare: management, analysis and future prospects," *J. Big Data*, vol. 6, no. 1, 2019, doi: 10.1186/s40537-019-0217-0.
- [97] A. Subasi and M. I. Gursoy, "EEG signal classification using PCA, ICA, LDA and support vector machines," *Expert Syst. Appl.*, vol. 37, no. 12, 2010, doi: 10.1016/j.eswa.2010.06.065.
- [98] A. L. Goldberger *et al.*, "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals.," *Circulation*, vol. 101, no. 23, 2000, doi: 10.1161/01.cir.101.23.e215.
- [99] N. A. Badcock, P. Mousikou, Y. Mahajan, P. De Lissa, J. Thie, and G. McArthur, "Validation of the Emotiv EPOC® EEG gaming system for measuring research quality auditory ERPs," *PeerJ*, vol. 2013, no. 1, 2013, doi: 10.7717/peerj.38.
- [100] R. Cassani, M. Estarellas, R. San-Martin, F. J. Fraga, and T. H. Falk, "Systematic review on resting-state EEG for Alzheimer's disease diagnosis and progression assessment," 2018. doi: 10.1155/2018/5174815.
- [101] B. T. Klassen *et al.*, "Quantitative EEG as a predictive biomarker for Parkinson disease dementia," *Neurology*, vol. 77, no. 2, 2011, doi: 10.1212/WNL.0b013e318224af8d.
- [102] X. Jiang, G. Bin Bian, and Z. Tian, "Removal of artifacts from EEG signals: A review," 2019. doi: 10.3390/s19050987.
- [103] C. Babiloni *et al.*, "International Federation of Clinical Neurophysiology (IFCN) – EEG research workgroup: Recommendations on frequency and topographic analysis of resting state EEG rhythms. Part 1: Applications in clinical research studies," 2020. doi: 10.1016/j.clinph.2019.06.234.
- [104] J. A. Urigüen and B. Garcia-Zapirain, "EEG artifact removal - State-of-the-art and guidelines," *J. Neural Eng.*, vol. 12, no. 3, 2015, doi: 10.1088/1741-2560/12/3/031001.

- [105] N. K. Al-Qazzaz, S. H. B. M. Ali, S. A. Ahmad, K. Chellappan, M. S. Islam, and J. Escudero, "Role of EEG as biomarker in the early detection and classification of dementia," 2014. doi: 10.1155/2014/906038.
- [106] B. Hjorth, "EEG analysis based on time domain properties," *Electroencephalogr. Clin. Neurophysiol.*, vol. 29, no. 3, 1970, doi: 10.1016/0013-4694(70)90143-4.
- [107] J. Jeong, "EEG dynamics in patients with Alzheimer's disease," 2004. doi: 10.1016/j.clinph.2004.01.001.
- [108] F. J. Fraga, T. H. Falk, P. A. M. Kanda, and R. Anghinah, "Characterizing Alzheimer's Disease Severity via Resting-Awake EEG Amplitude Modulation Analysis," *PLoS One*, vol. 8, no. 8, 2013, doi: 10.1371/journal.pone.0072240.
- [109] D. Ravi *et al.*, "Deep Learning for Health Informatics," *IEEE J. Biomed. Health Inform.*, vol. 21, no. 1, 2017, doi: 10.1109/JBHI.2016.2636665.
- [110] D. H. Wolpert and W. G. Macready, "No free lunch theorems for optimization," *IEEE Transactions on Evolutionary Computation*, vol. 1, no. 1, 1997, doi: 10.1109/4235.585893.
- [111] S. Lemm, B. Blankertz, T. Dickhaus, and K. R. Müller, "Introduction to machine learning for brain imaging," *Neuroimage*, vol. 56, no. 2, 2011, doi: 10.1016/j.neuroimage.2010.11.004.
- [112] F. Lotte *et al.*, "A review of classification algorithms for EEG-based brain – computer interfaces To cite this version: A Review of Classification Algorithms for EEG-based Brain-Computer Interfaces," *Hum. Brain Mapp.*, vol. 38, no. 11, 2018.
- [113] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016. doi: 10.1145/2939672.2939785.
- [114] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," 2002. doi: 10.1016/S1388-2457(02)00057-3.
- [115] P. D. Welch, "The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms," *IEEE Transactions on Audio and Electroacoustics*, vol. 15, no. 2, 1967, doi: 10.1109/TAU.1967.1161901.
- [116] W. Klimesch, "EEG alpha and theta oscillations reflect cognitive and memory performance: A review and analysis," 1999. doi: 10.1016/S0165-0173(98)00056-3.
- [117] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf. Process. Manag.*, vol. 45, no. 4, 2009, doi: 10.1016/j.ipm.2009.03.002.

- [118] C. Babiloni *et al.*, “Cortical sources of resting state electroencephalographic rhythms in Parkinson’s disease related dementia and Alzheimer’s disease,” *Clinical Neurophysiology*, vol. 122, no. 12, 2011, doi: 10.1016/j.clinph.2011.03.029.
- [119] D. F. Sittig *et al.*, “Grand challenges in clinical decision support,” *J. Biomed. Inform.*, vol. 41, no. 2, 2008, doi: 10.1016/j.jbi.2007.09.003.
- [120] N. Sharma, M. H. Kolekar, and K. Jha, “EEG based dementia diagnosis using multi-class support vector machine with motor speed cognitive test,” *Biomed. Signal Process. Control*, vol. 63, 2021, doi: 10.1016/j.bspc.2020.102102.
- [121] International Organization for Standardization, “Human-centred design for interactive systems (ISO Standard No. 9241-210:2019),” in *Ergonomics of human-system interaction*, 2019.
- [122] S. SAITO and K. OGAWA, “Ergonomics of human-system interaction,” *The Japanese journal of ergonomics*, vol. 30, no. 1, 1994, doi: 10.5100/jje.30.1.
- [123] ISO 9241-210, “Ergonomics of human system interaction Part 210 : Human-centred design for interactive systems,” *International Organization for Standardization*, vol. 10406–1:20, 2019.
- [124] S. Seifpour and A. Šatka, “Tensor Decomposition Analysis of Longitudinal EEG Signals Reveals Differential Oscillatory Dynamics in Eyes-Closed and Eyes-Open Motor Imagery BCI: A Case Report,” *Brain Sci.*, vol. 13, no. 7, 2023, doi: 10.3390/brainsci13071013.
- [125] M. Riaz, P. Guerra, and R. Gravina, “EEG Sensor-Based Computational Model for Personality and Neurocognitive Health Analysis Under Social Stress,” *Sensors*, vol. 25, no. 24, 2025, doi: 10.3390/s25247634.
- [126] J. Levitt, Z. Yang, S. D. Williams, S. E. Lütseh Espinosa, A. Garcia-Casal, and L. D. Lewis, “EEG-LLAMAS: A low-latency neurofeedback platform for artifact reduction in EEG-fMRI,” *Neuroimage*, vol. 273, 2023, doi: 10.1016/j.neuroimage.2023.120092.
- [127] G. Lasso Mendoza, *Reglamento de la Ley Orgánica de Protección de Datos Personales*. 2023.
- [128] MSP, “Manual de uso de los formularios básicos de la historia clínica única,” 2012.
- [129] A. A. Alshazly, M. Y. ElNainay, A. A. El-Zoghabi, and M. S. Abougabal, “A cloud software life cycle process (CSLCP) model,” *Ain Shams Engineering Journal*, vol. 12, no. 2, 2021, doi: 10.1016/j.asej.2020.11.004.
- [130] N. M. Jadhav and R. S. Shendge, “ISO 13485:2016-The Gateway of Global or Regional Harmonization for Medical Device Regulations,” 2024. doi: 10.25258/ijpqa.15.1.76.

- [131] A. W. Kushniruk and V. L. Patel, "Cognitive and usability engineering methods for the evaluation of clinical information systems," 2004. doi: 10.1016/j.jbi.2004.01.003.
- [132] V. Mirzaei, "The Impact of Color Psychology in Graphic Design: A Comprehensive Review," *International Journal of Scientific Research and Management (IJSRM)*, vol. 13, no. 03, 2025, doi: 10.18535/ijssrm/v13i03.ec04.
- [133] ISO/IEC 27001, "ISO/IEC 27001:2022 Information security, cybersecurity and privacy protection — Information security management systems — Requirements," *ISO/IEC Standard*, vol. 2022, 2022.
- [134] C. International and E. Commission, "IEC 62304:2006 : Medical device software - Software life cycle processes," 2006.
- [135] A. Cavoukian, "Understanding How to Implement Privacy by Design, One Step at a Time," *IEEE Consumer Electronics Magazine*, vol. 9, no. 2, 2020, doi: 10.1109/MCE.2019.2953739.
- [136] W. Moore and S. Frye, "Review of HIPAA, Part 1: History, protected health information, and privacy and security rules," *J. Nucl. Med. Technol.*, vol. 47, no. 4, 2019, doi: 10.2967/JNMT.119.227819.
- [137] R. N. Khushaba, S. Kodagoda, S. Lal, and G. Dissanayake, "Driver drowsiness classification using fuzzy wavelet-packet-based feature-extraction algorithm," *IEEE Trans. Biomed. Eng.*, vol. 58, no. 1, 2011, doi: 10.1109/TBME.2010.2077291.
- [138] J. C. Henry, "Electroencephalography: Basic Principles, Clinical Applications, and Related Fields, Fifth Edition," *Neurology*, vol. 67, no. 11, 2006, doi: 10.1212/01.wnl.0000243257.85592.9a.
- [139] C. Babiloni *et al.*, "Resting state cortical electroencephalographic rhythms are related to gray matter volume in subjects with mild cognitive impairment and Alzheimer's disease," *Hum. Brain Mapp.*, vol. 34, no. 6, 2013, doi: 10.1002/hbm.22005.
- [140] C. M. Bishop, "Bishop - Pattern Recognition And Machine Learning - Springer 2006," *Antimicrob. Agents Chemother.*, vol. 58, no. 12, 2014.
- [141] Y. Senkaya, C. Kurnaz, and F. Ozbilgin, "Enhancing Alzheimer's Diagnosis with Machine Learning on EEG: A Spectral Feature-Based Comparative Analysis," *Diagnostics*, vol. 15, no. 17, 2025, doi: 10.3390/diagnostics15172190.
- [142] C. J. C. Burges, "A tutorial on support vector machines for pattern recognition," *Data Min. Knowl. Discov.*, vol. 2, no. 2, 1998, doi: 10.1023/A:1009715923555.
- [143] H. H. JASPER, "The ten twenty electrode system of the international federation," *Electroencephalogr. Clin. Neurophysiol.*, vol. 10, 1958.

- [144] M. Guermandi, A. Cossettini, S. Benatti, and L. Benini, “A Wireless System for EEG Acquisition and Processing in an Earbud Form Factor with 600 Hours Battery Lifetime,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2022. doi: 10.1109/EMBC48229.2022.9871874.
- [145] M. Rahman, R. Hewitt, and B. I. Morshed, “Design and Packaging of a Custom Single-lead Electrocardiogram (ECG) Sensor Embedded with Wireless Transmission,” in *Proceedings of the 16th IEEE Dallas Circuits and Systems Conference, DCAS 2023*, 2023. doi: 10.1109/DCAS57389.2023.10130229.
- [146] Y. Tuncel, G. Bhat, J. Park, and U. Y. Ogras, “ECO: Enabling Energy-Neutral IoT Devices Through Runtime Allocation of Harvested Energy,” *IEEE Internet Things J.*, vol. 9, no. 7, 2022, doi: 10.1109/JIOT.2021.3106283.
- [147] C. Cortes and V. Vapnik, “Support-Vector Networks,” *Mach. Learn.*, vol. 20, no. 3, 1995, doi: 10.1023/A:1022627411411.

ANEXOS

Anexo A. Explicación de la Unidad de Procesamiento y Digitalización de Señales.

El procesamiento interno de las bioseñales es gestionado por un microprocesador de 32 bits basado en la arquitectura ARM Cortex-M4. Este componente actúa como el núcleo de Procesamiento Digital de Señales (DSP) del equipo de adquisición. Su función principal consiste en recibir los impulsos bioeléctricos analógicos captados por los electrodos de polímero semiseco en las topologías frontal, temporal y parietal (AF3, AF4, T7, T8 y Pz), ejecutar la conversión analógico-digital (ADC) de alta velocidad y empaquetar los registros de electroencefalografía (EEG). La capacidad de cómputo de este procesador garantiza que las microfluctuaciones corticales se traduzcan sin pérdida de resolución antes de ser canalizadas hacia el algoritmo de Inteligencia Artificial para la extracción del espacio vectorial continuo de 35 dimensiones, este es el proceso que realiza el microprocesador de la figura 46.



Figura 46. Núcleo ARM Cortex-M4[144]

Anexo B. Identificación del Sistema en Chip (SoC) de Transmisión Inalámbrica

Para garantizar un entorno de telemetría ininterrumpido y no invasivo para el paciente adulto mayor, la arquitectura incorpora el Sistema en Chip (SoC) Nordic nRF52840 el cual se visualiza en la figura 47. Este circuito integrado de ultra bajo consumo administra el protocolo de comunicación Bluetooth 5.0 Low Energy (BLE). Su implementación dentro del prototipo es crítica para establecer un enlace de datos robusto entre la diadema sensora y la estación de procesamiento computacional. Al mantener una latencia mínima y asegurar la integridad de los paquetes transmitidos, este transceptor de radiofrecuencia permite que la aplicación de software aísle, reciba y analice con exactitud matemática el segmento temporal de relajación clínica establecido (del segundo 90 al 120), el cual es indispensable para el trazado del hiperplano en la Máquina de Vectores de Soporte (SVM).



Figura 47. Núcleo ARM Cortex-M4[145]

Anexo C. Explicación de la Unidad de Medición Inercial para Mitigación de Artefactos

El control de las anomalías cinemáticas durante la evaluación topográfica se encuentra respaldado a nivel de hardware por el sensor TDK ICM-20948 que se visualiza en la figura 48, una Unidad de Medición Inercial (IMU) de 9 ejes que integra un acelerómetro, un giroscopio y un magnetómetro tridimensionales. En el contexto de la detección de patologías neuromotoras, la función de este microchip es trascendental para el manejo del ruido electromiográfico (EMG) y cinemático. Dado que los movimientos cervicales y las contracciones de la musculatura facial generan armónicos de alta frecuencia que pueden inducir falsos positivos de Parkinson temprano, el rastreo espacial de este chip justifica físicamente la implementación algorítmica del escudo de rechazo fijado en 800 μ V. Las variaciones posicionales abruptas registradas por el sensor inercial alteran drásticamente la amplitud de la señal, proporcionando la justificación técnica para que el software descarte de forma automática las ventanas temporales contaminadas por el movimiento del sujeto.



Figura 48. TDK InvenSense ICM-20948[146]

Anexo D. Protocolo de colocación ajuste y calibración del Casco

Este apartado expone el registro fotográfico del trabajo de campo con los pacientes adultos mayores. Se ilustra el despliegue físico del sistema, abarcando la colocación, ajuste y calibración de impedancia de los sensores semisecos del dispositivo BCI Emotiv Insight 2.0. Asimismo, se evidencia el estricto cumplimiento del protocolo clínico de inmovilidad y relajación, fundamental para la mitigación de artefactos electromiográficos (EMG) durante la telemetría. Cabe destacar que el registro visual garantiza la total anonimización de los sujetos de prueba, en estricto cumplimiento con la normativa ética y la Ley Orgánica de Protección de Datos Personales.




Figura D1. Posicionamiento anatómico y alineación topográfica del dispositivo Emotiv Insight 2.0



Figura D2. Proceso de colocación y calibración de impedancia del dispositivo BCI
Emotiv Insight 2.0.



Figura D3. Proceso de colocación y calibración de impedancia del dispositivo BCI
Emotiv Insight 2.0.



Figura D4. Estación de monitoreo y telemetría de datos en tiempo real.



Figura D5. Aplicación estricta del protocolo de inmovilidad para mitigación de artefactos miogénicos.

Anexo E. Fase Clínica y Adquisición de Bioseñales

Este anexo documenta la arquitectura del lado del usuario final a través de la interfaz gráfica desarrollada. Las capturas de pantalla detallan el flujo operativo integral de la plataforma médica: desde los protocolos de autenticación y las instrucciones de preparación, hasta la visualización matemática del procesamiento de las bioseñales (densidad espectral de potencia y mapeo de biomarcadores). Finalmente, se demuestra la operatividad del modelo de Inteligencia Artificial (SVM) mediante la emisión del pre-diagnóstico de riesgo y la generación automatizada del reporte clínico exportable.



Figura E1. Interfaz de autenticación y control de acceso basado en roles (Investigador / Médico / Paciente).



Portal del Paciente - Preparación Clínica

Bienvenido al sistema de preparación para el examen neuro-computacional. Por favor, lea detenidamente el siguiente protocolo clínico estandarizado antes de iniciar la sesión de monitoreo con el especialista.

Fase 1: Preparación Previa al Examen

Para garantizar la correcta adquisición de sus bioseñales (EEG), es indispensable cumplir con los siguientes lineamientos antes de presentarse al consultorio:

- **Higiene Capilar:** El cabello debe estar limpio y completamente seco. Evite estrictamente el uso de geles, fijadores, acondicionadores sin enjuague o aceites capilares, ya que estos actúan como aislantes eléctricos y bloquean la señal de los sensores.
- **Estimulantes:** Absténgase de consumir bebidas con alto contenido de cafeína o energizantes al menos 4 horas antes del examen para evitar alteraciones en los ritmos Beta.
- **Descanso:** Procure haber mantenido un ciclo regular de sueño la noche anterior a la prueba.

Figura E2. Fase 1 del Protocolo de preparación e instrucciones clínicas en el portal del paciente.

Fase 2: Colocación y Calibración

El especialista procederá a colocar el dispositivo **Emotiv Insight 2.0** en su cabeza.

- El casco cuenta con sensores de polímero semiseco. Sentirá una ligera presión en las sienes, la frente y la parte posterior del cráneo.
- Es posible que el especialista humedezca ligeramente los electrodos con una solución salina para mejorar la conductividad.
- Durante los primeros 30 segundos, el sistema calibrará la impedancia (calidad de contacto). Se le solicitará mantenerse quieto mientras los indicadores del software alcanzan el color verde óptimo.

Fase 3: Adquisición de Señal en Reposo

Este es el momento crítico del examen de tamizaje, el cual dura aproximadamente de 1 a 3 minutos.

- **Postura:** Siéntese en una posición cómoda, con la espalda recta y las manos apoyadas sobre sus muslos.
- **Inmovilidad Facial:** Es vital **evitar parpadear repetidamente, tragar saliva o apretar la mandíbula**. Los músculos faciales generan "artefactos miogénicos" que contaminan la señal eléctrica del cerebro.
- **Estado de Relajación:** Cierre los ojos suavemente cuando el especialista se lo indique. Respire de forma calmada y natural. Intente dejar la mente en blanco, evitando cálculos mentales o evocar pensamientos estresantes.

Figura E3. Fase 2 y 3 del Protocolo de preparación e instrucciones clínicas en el portal del paciente.

Fase 4: Finalización y Reporte

Una vez concluido el tiempo estipulado, el especialista retirará el dispositivo. La Inteligencia Artificial procesará los datos adquiridos y generará un reporte de **Posible Diagnóstico Computacional** de manera inmediata. El especialista discutirá los resultados obtenidos con usted.

💡 Si tiene alguna duda sobre este protocolo, por favor consúltelo con su médico neurólogo o el investigador a cargo antes de iniciar la colocación del equipo.

Estimado paciente: Queremos garantizarle que toda la información recopilada durante este examen neuro-computacional será tratada con absoluta confidencialidad, respeto y rigor ético. En estricto cumplimiento con la Ley Orgánica de Protección de Datos Personales (LOPDP), sus registros electroencefalográficos (EEG) y su información de identidad serán completamente anónimos y resguardados bajo protocolos de encriptación de alta seguridad.

Figura E4. Fase 4 del Protocolo de preparación e instrucciones clínicas en el portal del paciente.

☒ Archivo EEG detectado. Listo para análisis topográfico de alta dimensionalidad.

Iniciar Análisis Neuro-Computacional

▼ Procesando bioseñales bajo protocolos seguros de la IEC 62304...

Cargando cerebro de IA (SVM)
 Inspeccionando formato e importando traza continua...
 Aislando fase de relajación pura con ojos cerrados (Segundos 90 al 120)...
 ⌚ Longitud total del registro detectada: 132 segundos.
 Aislando fase de relajación pura (Segundos 90 al 120)...
 Aplicando filtrado espectral...
☒ Se recuperaron 26 ventanas limpias para el diagnóstico.

Figura E5. Análisis Neuro-Computacional.




Figura E6. Interfaz de configuración técnica y supervisión algorítmica para el perfil de investigador



Figura E7. Interfaz de visualización de resultados y soporte a la decisión clínica para el perfil de médico neurólogo.

ANEXO A LA HISTORIA CLINICA (FORMULARIO 002) - REPORTE CDSS

Sistema de Soporte a la Decision Clinica basado en Maquinas de Vectores de Soporte (SVM)

1. Datos del Paciente

Fecha de Evaluacion: 2026-06-02 11:57:22

Paciente: N 001

Identidad (C.I): NO DISPONIBLE

Antecedentes Familiares: NO

2. Parametros Tecnicos de Adquisicion

Dispositivo: Emotiv Insight 2.0 (Sensores de polimero semiseco)

Fase Evaluada: Ojos Cerrados (90s - 120s) | Fs: 128 Hz

Topologia de Canales (Sistema 10-20): AF3, AF4, T7, T8, Pz

3. Analisis de Densidad Espectral de Potencia (PSD)

Delta (1.0-4Hz)	Theta (4-8Hz)	Alpha (8-13Hz)	Beta (13-30Hz)	Gamma (30-50Hz)
77.97%	14.61%	2.21%	4.03%	1.17%

4. Impresion Computacional de Riesgo

Resultado de la Red: Su análisis temprano no revela marcadores topográficos asociados a Deterioro Cognitivo (ALZHEIMER) ni Parkinson.

Firma del Paciente (C.I: NO DISPONIBLE)

Firma del Medico / Operador Tecnico

Figura E8. Anexo generado a la Historia Clínica Única