



Sistema Predictivo Multimodal para la Detección Temprana y Prevención del Síndrome de Burnout en Entornos Laborales

Leandro Reyes Jordan

Universidad EAN

Facultad de Ingeniería

Maestría en Ciencias de Datos

Bogotá, Colombia

28/mayo/2026

Sistema Predictivo Multimodal para la Detección Temprana y Prevención del Síndrome de Burnout en Entornos Laborales

Leandro Reyes Jordan

Trabajo de grado presentado como requisito para optar al título de:

Magister en Ciencias de Datos

Director:

Luis Armando Cobo Campo

Modalidad:

Monografía

Universidad EAN

Facultad de Ingeniería

Maestría en Ciencias de Datos

Bogotá, Colombia

28/mayo/2026

Nota de aceptación:

Firma del jurado

Firma del jurado

Firma del director del trabajo de grado

Ciudad, día/mes/año

A mi madre, por su amor incondicional, su
paciencia y su apoyo constante a lo largo
de mi vida,
por ser mi mayor inspiración y por
enseñarme, con su ejemplo, que la
perseverancia y la disciplina hacen posible
cualquier meta.

Este logro es también suyo.

Agradecimientos

A mi familia, por su apoyo incondicional, comprensión y acompañamiento durante todo este proceso, por ser el pilar fundamental que me impulsó a seguir adelante en los momentos más exigentes.

A mi profesor y asesor, Luis Armando Cobo Campo, por su guía, dedicación y valiosos aportes académicos, los cuales fueron fundamentales para el desarrollo y culminación de este trabajo de investigación.

A todas aquellas personas que, de una u otra manera, contribuyeron a la realización de este logro.

Resumen

En este trabajo se diseñó e implementó un sistema predictivo multimodal para la detección temprana y prevención del síndrome de burnout en entornos laborales. La investigación partió de la necesidad de complementar los métodos tradicionales basados en cuestionarios, incorporando señales adicionales derivadas del análisis de texto y del reconocimiento de emociones faciales.

Como base empírica, se recolectó una muestra inicial de 110 respuestas mediante el Maslach Burnout Inventory (MBI), a partir de la cual se construyó un dataset semilla para el análisis estadístico y el entrenamiento preliminar de modelos predictivos.

Debido a que los primeros resultados mostraron métricas excesivamente altas en una muestra limitada, se implementó una simulación Monte Carlo para ampliar el escenario experimental a 5.000 registros y obtener un contexto de evaluación más estable. La metodología integró análisis estadístico en IBM SPSS Statistics, modelos de machine learning y el desarrollo de un prototipo funcional en Streamlit, con almacenamiento en MongoDB y generación de alertas tempranas.

Los resultados evidenciaron que el agotamiento emocional y la despersonalización fueron variables relevantes en la predicción del riesgo de burnout. Asimismo, el enfoque multimodal permitió enriquecer la interpretación del riesgo al integrar información procedente del MBI, del análisis textual y de señales emocionales complementarias.

Se concluyó que la propuesta es técnicamente viable y metodológicamente pertinente como prototipo de detección temprana, aunque requiere validación futura con datos multimodales reales, muestras más amplias y evaluación en contextos organizacionales diversos.

Palabras clave: burnout, MBI, machine learning, análisis multimodal, alertas tempranas, salud ocupacional.

Abstract

In this study, a multimodal predictive system was designed and implemented for the early detection and prevention of burnout syndrome in work environments. The research was based on the need to complement traditional questionnaire-based methods by incorporating additional signals derived from text analysis and facial emotion recognition. As an empirical basis, an initial sample of 110 responses was collected using the Maslach Burnout Inventory (MBI), from which a seed dataset was built for statistical analysis and preliminary predictive modeling.

Since the initial results showed excessively high metrics in a limited sample, a Monte Carlo simulation was implemented to expand the experimental scenario to 5,000 records and obtain a more stable evaluation context. The methodology integrated statistical analysis in IBM SPSS Statistics, machine learning models, and the development of a functional prototype in Streamlit, with MongoDB storage and an early alert system. The results showed that emotional exhaustion and depersonalization were relevant variables in predicting burnout risk. Likewise, the multimodal approach enriched risk interpretation by integrating information from the MBI, textual analysis, and complementary emotional signals.

It was concluded that the proposal is technically feasible and methodologically relevant as an early detection prototype, although future validation with real multimodal data, larger samples, and evaluation in diverse organizational contexts is required.

Keywords: burnout, MBI, machine learning, multimodal analysis, early alerts, occupational health.

Contenido

	<i>Pág.</i>
Introducción.....	17
Antecedentes Del Problema	17
Antecedentes investigativos	18
Descripción Del Problema	26
Pregunta De Investigación	26
Objetivos	27
Objetivo General	27
Objetivos Específicos	27
Justificación	28
Marco Teórico.....	30
Definición, Conceptualización y Dimensiones del Burnout	31
Diferenciación entre Burnout y Depresión.....	32
Evolución Histórica y Contextualización.....	33
Factores de Riesgo Asociados	36
Hipótesis.....	44
Hipótesis Primaria	44
Hipótesis Secundaria (Causal).....	45
Variables	48
Variable 1. Riesgo de Burnout.....	48

	10	
Variable 2. Análisis de sentimientos (datos textuales).....	49	
Variable 3. Patrones de comportamiento laboral	50	
Variable 4. Expresiones faciales	51	
Variable 5. Efectividad del sistema de alertas	51	
Metodología.....	53	
Enfoque de la investigación	53	
Diseño y tipo de estudio	53	
Fases Metodológicas por Objetivo Específico	54	
Población y muestra	58	
Instrumento de medición y validación.....	59	
Procedimientos y técnicas de análisis de la información.....	60	
Trabajo de Campo	62	
Descripción de la labor de investigación realizada.....	63	
Recolección de datos e instrumentos utilizados	65	
Procesamiento y preparación de los datos.....	70	
Resultados iniciales con la muestra semilla y escenario experimental.....	73	
Métricas de evaluación de los modelos predictivos.....	74	
Generación del conjunto sintético mediante simulación Monte Carlo	78	
Análisis cuantitativo tradicional en IBM SPSS Statistics.....	82	
Modelado predictivo monomodal y contraste con machine learning.....	87	
Construcción del enfoque multimodal	89	

	11	
Diseño e implementación del prototipo funcional.....	98	
Análisis de resultados.....	105	
Propuesta de solución a la problemática	107	
Evidencia visual de la implementación del prototipo	110	
Cierre del capítulo.....	117	
Discusión.....	118	
Conclusiones y Trabajo Futuro.....	124	
Conclusiones	124	
Trabajo futuro	126	
Referencias	129	
Anexos.	141	
A. Anexo. Cuestionario Maslach Burnout Inventory (MBI)	142	
B. Anexo. Resultados de la simulación en IBM SPSS Statistics.....	143	
C. Anexo. Dataset de la muestra inicial de 110 usuarios.....	144	
D. Anexo. Dataset de simulación Monte Carlo de 5.000 registros	144	
E. Anexo. Estructura de la solución desarrollada en Streamlit	145	

Lista de Figuras

Figura 1 Diagrama general del trabajo de campo, desde la recolección MBI hasta la implementación del prototipo multimodal.	64
Figura 2 Mapa de instrumentos y herramientas utilizadas, diferenciando MBI, SPSS, Python, PySentimiento, DeepFace, Streamlit y MongoDB.....	69
Figura 3 Captura del análisis inicial del dataset de 110 registros y comentario visual sobre el riesgo de sobreajuste.	77
Figura 4 Diagrama del procedimiento de simulación Monte Carlo desde el dataset semilla hasta el dataset de 5.000 registros	80
Figura 5 Scores de EE_total, DP_total y RP_total del dataset Monte Carlo.	85
Figura 6 Esquema del procedimiento en SPSS, desde importación .sav hasta correlación y regresión.....	86
Figura 7 Diagrama comparativo entre el método tradicional, el enfoque monomodal con machine learning y el enfoque multimodal.	89
Figura 8 Esquema visual de la ecuación multimodal y del efecto de los pesos o del delta acotado sobre la probabilidad final.	98
Figura 9 Arquitectura técnica del prototipo, mostrando flujo entre Streamlit, modelos predictivos, MongoDB y sistema de alertas.....	101
Figura 10 Interfaz Streamlit con las pestañas Evaluación, Histórico y Simulador.	105
Figura 11 Comparación conceptual y metodológica entre enfoque tradicional, monomodal y multimodal.....	107
Figura 12 Arquitectura final de la solución propuesta, incluyendo captura de datos, modelos, MongoDB, histórico y alertas.	109
Figura 13 Arquitectura de solución para predicción de agotamiento.....	110

Figura 14 Panel general del prototipo con diagnóstico de conexión, reglas de alerta y métricas del modelo	111
Figura 15 Vista del módulo de evaluación del empleado con diligenciamiento del cuestionario MBI de 22 ítems.....	112
Figura 16 Vista del módulo histórico de RRHH con registro de evaluaciones y alertas generadas	112
Figura 17 Vista del módulo simulador para ejecución de pruebas automáticas del flujo de evaluación	113
Figura 18 Pantalla de configuración de evaluación multimodal con carga de imagen, comentario de texto y parámetros del ensamble	113
Figura 19 Selección de modelos de evaluación disponibles en la interfaz del prototipo	113
Figura 20 Resultados de la evaluación multimodal con probabilidades estimadas, niveles de riesgo y activación de alertas	114
Figura 21 Notificación de alerta enviada automáticamente al canal de Microsoft Teams	115
Figura 22 Vista general de la base de datos MongoDB con las colecciones BurnoutAssessments y BurnoutAlerts.....	115
Figura 23 Registro de una alerta almacenada en la colección BurnoutAlerts de MongoDB.....	116
Figura 24 Registro de una evaluación almacenada en la colección BurnoutAssessments de MongoDB.....	116

Lista de Tablas

Tabla 1 Tabla de siglas y abreviaturas	15
Tabla 2 Correspondencia entre los 22 ítems del MBI, la dimensión a la que pertenecen y la escala de respuesta utilizada.	66
Tabla 3 Rangos de interpretación del MBI para EE, DP y RP, indicando niveles bajo, medio y alto.....	68
Tabla 4 Estructura final del dataset semilla, indicando ítems MBI, subtotales, variable objetivo y variables preparadas para el enfoque multimodal.	72
Tabla 5 Resultados preliminares de Regresión Logística, Random Forest y SVM sobre la muestra semilla, incluyendo accuracy, recall, F1-score y AUC-ROC.	77
Tabla 6 Comparación entre dataset semilla y dataset Monte Carlo, incluyendo número de casos, variables, medias y dispersión por dimensión.	81
Tabla 7 Indicadores psicométricos y descriptivos del dataset Monte Carlo, incluyendo alfa de Cronbach, medias, desviaciones estándar, mínimos y máximos.	84
Tabla 8 Matriz de correlaciones de Spearman entre las dimensiones del MBI y la variable Burnout_alto en el dataset Monte Carlo	85
Tabla 9 Resumen del modelo de regresión en SPSS para el dataset Monte Carlo.	86
Tabla 10 Comparación entre Regresión Logística, Random Forest y SVM en el enfoque monomodal.	88
Tabla 11 Definición de p_MBI, p_sent, p_emo, pesos del ensamble y estrategia de integración.	96
Tabla 12 Campos principales almacenados en las colecciones BurnoutAssessments y BurnoutAlerts.....	102

Lista de siglas y abreviaturas

A continuación, se presentan las principales siglas y abreviaturas utilizadas en el documento, con el fin de facilitar la lectura y comprensión de los conceptos técnicos, metodológicos y estadísticos empleados en la investigación.

Tabla 1
Tabla de siglas y abreviaturas

Sigla	Significado	Descripción breve
API	Application Programming Interface	Interfaz que permite la comunicación entre sistemas o aplicaciones.
AUC	Area Under the Curve	Área bajo la curva ROC; mide la capacidad discriminativa del modelo.
AUC-ROC	Area Under the Receiver Operating Characteristic Curve	Métrica que resume el desempeño del modelo para diferenciar clases.
BOS	Burnout Syndrome	Síndrome de burnout o síndrome de desgaste ocupacional.
CIE-11	Clasificación Internacional de Enfermedades, 11. ^a edición	Clasificación internacional de enfermedades y condiciones de salud.
CSV	Comma-Separated Values	Formato de archivo para almacenar datos tabulares.
DP	Despersonalización	Dimensión del burnout asociada al distanciamiento, cinismo o trato impersonal.
EE	Agotamiento emocional	Dimensión del burnout asociada al cansancio emocional persistente.
F1-score	Puntaje F1	Media armónica entre precisión y sensibilidad o recall.
FN	Falso negativo	Caso positivo clasificado erróneamente como negativo.
FP	Falso positivo	Caso negativo clasificado erróneamente como positivo.
HPA	Eje hipotalámico-hipofisario-adrenal	Sistema neuroendocrino asociado a la respuesta fisiológica al estrés.
HR	Hazard Ratio	Medida de riesgo relativo utilizada en estudios de tiempo hasta evento.
IA	Inteligencia artificial	Campo orientado al desarrollo de sistemas capaces de ejecutar tareas asociadas a la inteligencia humana.

Sigla	Significado	Descripción breve
LR	Logistic Regression / Regresión logística	Modelo de clasificación supervisada usado para estimar probabilidades de pertenencia a una clase.
MBI	Maslach Burnout Inventory	Instrumento psicométrico utilizado para evaluar el síndrome de burnout.
ML	Machine Learning / Aprendizaje automático	Rama de la inteligencia artificial que permite entrenar modelos a partir de datos.
NLP	Natural Language Processing / Procesamiento de lenguaje natural	Técnicas para analizar, interpretar y procesar lenguaje humano.
OMS	Organización Mundial de la Salud	Organismo internacional especializado en salud pública.
OR	Odds Ratio	Razón de probabilidades usada para estimar asociación entre una exposición y un evento.
p	Valor p	Indicador de significancia estadística.
RF	Random Forest	Algoritmo de aprendizaje automático basado en múltiples árboles de decisión.
ROC	Receiver Operating Characteristic	Curva que relaciona la sensibilidad con la tasa de falsos positivos.
RP	Realización personal	Dimensión del burnout asociada a la percepción de logro y eficacia profesional.
RR	Riesgo relativo	Medida que compara la probabilidad de ocurrencia de un evento entre dos grupos.
RRHH	Recursos Humanos	Área organizacional encargada de la gestión del talento humano.
SPSS	Statistical Package for the Social Sciences	Software estadístico utilizado para análisis cuantitativo.
SVM	Support Vector Machine / Máquina de vectores de soporte	Algoritmo de clasificación supervisada utilizado en aprendizaje automático.
VN	Verdadero negativo	Caso negativo clasificado correctamente como negativo.
VP	Verdadero positivo	Caso positivo clasificado correctamente como positivo.
XAI	Explainable Artificial Intelligence / Inteligencia artificial explicable	Enfoque orientado a interpretar y explicar las decisiones de los modelos de inteligencia artificial.
β	Beta	Coefficiente usado en modelos estadísticos para representar magnitud o dirección de asociación.

Introducción

El bienestar laboral se ha convertido en un tema de gran relevancia en el ámbito organizacional contemporáneo, especialmente en un mundo altamente competitivo y dinámico donde las demandas profesionales aumentan constantemente. En este contexto, los riesgos psicosociales, como el Síndrome de Burnout, han adquirido una importancia significativa debido a sus efectos negativos tanto en la salud de los trabajadores como en el desempeño de las organizaciones. Comprender este fenómeno, sus causas y posibles soluciones resulta fundamental para promover entornos laborales más saludables y sostenibles, en los que la tecnología, y en particular la inteligencia artificial, ofrece nuevas oportunidades para la prevención y el manejo temprano de este problema.

Antecedentes Del Problema

El Síndrome de Burnout es un fenómeno laboral cada vez más prevalente, causado por el estrés crónico en el lugar de trabajo. Este síndrome se caracteriza por el agotamiento emocional, la despersonalización y la reducción de la realización personal en el trabajo (Wikipedia, abril, 2025). Las causas del Burnout incluyen cargas de trabajo excesivas, falta de control, recompensas escasas, falta de comunidad, trato injusto, valores no alineados, entornos tóxicos, expectativas poco realistas y liderazgo deficiente (Herrity, 2024). Aunque el Burnout afecta a diversas profesiones, ha sido especialmente estudiado en el sector de la salud (Vňuková et al, 2023). La pandemia de COVID-19 ha exacerbado el problema, aumentando el estrés laboral y la necesidad de intervenciones efectivas (Amos, 2023).

La tecnología, particularmente el Machine Learning (ML), ha demostrado ser útil en la detección temprana del Burnout al analizar patrones en datos de empleados, como comunicaciones escritas y comportamientos laborales (Mascha Kurpicz-Briki, 2024). Sin embargo, la mayoría de los sistemas existentes no integran múltiples fuentes de datos ni ofrecen alertas tempranas personalizadas para la prevención del Burnout (Quarksup, 2024).

Antecedentes investigativos

Esta sección presenta investigaciones previas relacionadas con el síndrome de burnout, su evaluación psicométrica, el uso de modelos predictivos y la incorporación de señales complementarias como texto y expresiones faciales. Su propósito es diferenciar los antecedentes investigativos de los antecedentes del problema, de manera que los estudios revisados funcionen como referentes comparativos para la discusión de los resultados obtenidos en esta tesis.

Estudios clásicos y psicométricos sobre burnout

La investigación sobre el síndrome de burnout se consolidó inicialmente en el campo de las profesiones de servicio, donde las demandas emocionales y el contacto interpersonal sostenido generan condiciones propicias para el desgaste laboral. (Freudenberger, 1974) introdujo el término staff burn-out para describir un estado de agotamiento físico y psicológico asociado al trabajo asistencial. Posteriormente, (Maslach & Jackson, 1981) propusieron una medición sistemática del fenómeno mediante el Maslach Burnout Inventory (MBI), instrumento que permitió operacionalizar el burnout como un constructo multidimensional y no como una simple fatiga ocasional.

El modelo tridimensional de Maslach se estructuró en tres dimensiones: agotamiento emocional, despersonalización y baja realización personal. El agotamiento emocional representa la pérdida de energía y recursos afectivos frente a las exigencias del trabajo; la despersonalización alude al distanciamiento, cinismo o trato impersonal hacia usuarios, pacientes, clientes o compañeros; y la baja realización personal se relaciona con la percepción de ineficacia o disminución del logro profesional (Maslach & Jackson, 1981) (Maslach C. S., 2001). Esta estructura ha sido ampliamente utilizada en investigaciones laborales, aunque su aplicación exige considerar el contexto ocupacional, cultural e institucional en el que se administra el instrumento.

En este marco, el MBI se posicionó como una de las herramientas psicométricas más influyentes para el estudio del burnout. Sus versiones para servicios humanos, educación y contextos generales de trabajo han permitido comparar resultados entre ocupaciones y países; sin embargo, también se ha señalado que los puntos de corte y las adaptaciones culturales pueden modificar la forma de clasificar el riesgo. (Soares, Lopes, Mendonça, Rodrigues, & Castro, 2023), en una revisión de alcance sobre el uso del MBI en profesionales de servicios públicos de salud, identificaron múltiples versiones del instrumento, diferencias en escalas de respuesta y variaciones en los criterios de clasificación. Este antecedente es relevante para la presente tesis porque confirma que el MBI constituye una base psicométrica sólida, pero que sus resultados deben interpretarse según el contexto metodológico y la población evaluada.

Investigaciones sobre burnout en entornos laborales

Los estudios empíricos sobre burnout han documentado su presencia en sectores laborales con alta carga emocional, como salud, educación, servicios sociales y organizaciones con exigencias continuas de productividad. La revisión de (Maslach C. S., 2001) integró décadas de investigación y mostró que el burnout surge de la interacción entre demandas laborales persistentes, recursos insuficientes, falta de control, ausencia de reconocimiento, conflicto de valores y deterioro del sentido de comunidad laboral. En investigaciones posteriores, (Maslach & Leiter, 2016) reforzaron la idea de que el burnout debe comprenderse desde la relación entre persona y organización, más que como una condición atribuible exclusivamente al individuo.

En el sector salud, los antecedentes investigativos muestran que el burnout afecta no solo el bienestar del trabajador, sino también variables organizacionales como calidad del servicio, intención de rotación, ausentismo, satisfacción laboral y percepción de seguridad. Las revisiones que emplean instrumentos como el MBI y el Copenhagen Burnout Inventory han resaltado que los niveles de agotamiento emocional suelen ser especialmente sensibles a la carga laboral, la presión asistencial y la insuficiencia de recursos (Alahmari & Moaleem, 2022) (Soares, Lopes, Mendonça, Rodrigues, & Castro, 2023). Estos hallazgos son importantes para esta investigación porque justifican la necesidad de pasar de mediciones aisladas y reactivas a mecanismos de apoyo que permitan identificar señales tempranas de riesgo.

En educación y otros sectores de servicios también se ha observado una relación entre burnout, carga de trabajo, reconocimiento institucional y percepción de eficacia profesional. Aunque cada ocupación presenta dinámicas propias, la literatura coincide en que el fenómeno se

expresa mediante patrones que combinan agotamiento, distanciamiento actitudinal y deterioro de la autovaloración profesional. Esta evidencia respalda el uso del MBI como punto de partida en sistemas de análisis, pero también sugiere la conveniencia de integrar otras señales que permitan enriquecer la comprensión del riesgo en entornos laborales reales.

Modelos predictivos y machine learning aplicados al burnout

El avance de la ciencia de datos ha impulsado investigaciones orientadas a aplicar modelos predictivos y técnicas de aprendizaje automático al estudio del burnout. Estos enfoques buscan identificar patrones de riesgo a partir de variables psicométricas, demográficas, laborales y organizacionales. A diferencia de los análisis estadísticos tradicionales, los modelos de machine learning pueden capturar relaciones no lineales entre múltiples variables, aunque su utilidad depende de la calidad de los datos, el tamaño muestral, la validación externa y la interpretación responsable de los resultados. (Baniadamdzaj & Baniadamdzaj, 2023) aplicaron algoritmos de aprendizaje automático para predecir niveles de burnout en docentes de inglés como lengua extranjera, empleando el MBI como instrumento base y comparando distintos clasificadores.

Este estudio es un antecedente directo porque combina medición psicométrica con modelos computacionales de clasificación. De manera similar, (Van Zyl-Cillie, Bührmann, Blignaut, Demirtas, & Coetzee, 2024) desarrollaron modelos supervisados para predecir sentimientos de burnout y agotamiento emocional en personal de enfermería en Sudáfrica. En este caso, los modelos se evaluaron mediante métricas como exactitud, AUC y matriz de

confusión, lo cual coincide con la necesidad de interpretar el desempeño predictivo desde varias métricas y no únicamente desde un indicador global.

Estos antecedentes muestran que el machine learning puede ser útil como herramienta de apoyo para clasificar riesgo o identificar factores asociados al burnout; sin embargo, también evidencian limitaciones relevantes. En primer lugar, la mayor parte de los modelos se apoya en cuestionarios estructurados o variables de encuesta. En segundo lugar, los resultados suelen depender de muestras específicas y pueden no generalizarse automáticamente a otros contextos. En tercer lugar, los modelos predictivos no deben ser interpretados como diagnósticos clínicos, sino como mecanismos de apoyo para la detección preliminar y la toma de decisiones en salud ocupacional. Esta postura es coherente con las recomendaciones internacionales sobre salud mental en el trabajo, que priorizan intervenciones preventivas, organizacionales y éticamente responsables (World Health Organization., 2022). Esta lectura prudente también es coherente con la presente investigación, que propone un prototipo funcional y un escenario experimental, sin afirmar validación definitiva con datos multimodales reales.

Procesamiento de lenguaje natural y análisis de sentimientos

Otra línea reciente de investigación se orienta al uso de procesamiento de lenguaje natural (NLP) y análisis de sentimientos para identificar señales lingüísticas asociadas a estrés, agotamiento o malestar emocional. El interés de este enfoque radica en que las comunicaciones escritas pueden contener patrones relacionados con negatividad emocional, desmotivación, fatiga, frustración o cinismo. No obstante, el lenguaje está condicionado por el contexto, la cultura organizacional, el

estilo comunicativo de cada persona y las normas del medio digital utilizado, por lo que su análisis debe entenderse como una señal complementaria y no como una prueba concluyente. (Kurpicz-Briki & Merhbene, 2024) exploraron el uso de modelos de clasificación textual para identificar indicios de burnout en datos escritos, combinando fuentes en línea con datos reales y resaltando la importancia de la colaboración entre especialistas en inteligencia artificial y expertos clínicos u ocupacionales. Aunque se trata de un trabajo en formato de preprint, constituye un antecedente pertinente porque muestra el potencial del NLP para analizar expresiones textuales relacionadas con burnout y, al mismo tiempo, reconoce la necesidad de datos reales, interpretabilidad y validación interdisciplinaria. En relación con la presente investigación, esta línea respalda la incorporación del análisis textual como una capa adicional de información, siempre subordinada a una interpretación ética y contextualizada.

El análisis de sentimientos puede aportar valor cuando se combina con instrumentos psicométricos validados, ya que permite observar señales expresivas que no siempre quedan capturadas en una escala cerrada. Sin embargo, su aplicación en entornos laborales exige protección de datos, consentimiento informado, transparencia y límites claros de uso. Por ello, en esta tesis el análisis textual se concibe como un complemento del MBI y no como un reemplazo de la evaluación profesional o psicométrica.

Reconocimiento de emociones faciales y enfoques multimodales

El reconocimiento de emociones faciales y el análisis multimodal han sido explorados en estudios sobre estrés, salud mental y bienestar laboral. En el caso específico del burnout, (Colonnello & Carnevali, 2021) evaluaron a profesionales de la salud mediante el MBI y una

tarea experimental de reconocimiento dinámico de emociones faciales. Sus resultados sugirieron que las personas con mayor burnout o mayor despersonalización podían presentar alteraciones selectivas en el reconocimiento de emociones negativas. Este antecedente resulta especialmente relevante porque conecta el burnout con el procesamiento de señales emocionales faciales, aunque no constituye por sí mismo un sistema predictivo automatizado.

Los estudios de análisis facial y multimodal suelen trabajar en escenarios controlados y, en muchos casos, se enfocan en estrés general más que en burnout certificado mediante escalas psicométricas. Por esta razón, deben ser entendidos como antecedentes indirectos cuando se trasladan al estudio del burnout laboral. Su aporte principal consiste en mostrar que las señales no verbales pueden contener información relacionada con estados afectivos y de tensión; sin embargo, estas señales presentan alta variabilidad individual y cultural, además de implicaciones éticas asociadas a privacidad, consentimiento y vigilancia laboral. En consecuencia, cualquier uso de reconocimiento emocional en el trabajo debe limitarse a fines preventivos, con mecanismos transparentes y sin sustituir la valoración humana.

Desde la perspectiva multimodal, la integración de datos psicométricos, textuales y emocionales puede enriquecer la identificación preliminar de riesgo porque cada fuente aporta información distinta. El MBI ofrece una medición estructurada y validada; el texto puede reflejar señales lingüísticas de malestar; y el análisis facial puede aportar señales no verbales asociadas a expresiones emocionales. No obstante, la integración de estas fuentes requiere diseño metodológico cuidadoso, validación externa y evaluación ética permanente.

Brecha investigativa y relación con este trabajo de investigación

A partir de los antecedentes revisados, se identifica una brecha investigativa clara. Existen estudios consolidados sobre burnout mediante el MBI, investigaciones sobre sus factores laborales y organizacionales, trabajos recientes que aplican machine learning a datos psicométricos y propuestas emergentes que emplean NLP o análisis facial para detectar señales asociadas a malestar emocional. Sin embargo, todavía son limitadas las investigaciones que integran de forma explícita estas fuentes en un sistema predictivo multimodal orientado a la detección temprana del burnout y a la generación de alertas preventivas. En este sentido, la presente investigación se ubica en un punto de convergencia entre la psicometría del burnout y la ciencia de datos aplicada a salud ocupacional. Su aporte consiste en proponer un prototipo funcional que combina el MBI como base psicométrica, modelos de machine learning como componente predictivo, análisis textual como señal conductual y análisis de emociones faciales como señal complementaria. La simulación Monte Carlo permitió ampliar el escenario experimental a 5.000 registros para explorar mayor variabilidad y estabilidad analítica, aunque no sustituye la necesidad de validación futura con datos multimodales reales.

Por tanto, el sistema desarrollado debe comprenderse como una herramienta de apoyo para la detección preliminar del riesgo y no como un diagnóstico definitivo de burnout. Esta delimitación metodológica permite responder al comentario académico sobre la necesidad de antecedentes investigativos: los estudios previos sirven como base de comparación para discutir los resultados de esta tesis, especialmente en tres aspectos. Primero, el MBI se mantiene como instrumento central de referencia. Segundo, los modelos predictivos permiten explorar patrones de riesgo, pero deben interpretarse con cautela. Tercero, las señales textuales y faciales

pueden aportar información complementaria, aunque requieren validación empírica, control ético y evaluación contextual. De este modo, la investigación aporta una propuesta integradora que articula antecedentes clásicos y recientes, sin sobredimensionar el alcance del prototipo.

Descripción Del Problema

El Síndrome de Burnout es un problema creciente en entornos laborales, caracterizado por agotamiento emocional, despersonalización y disminución de la realización personal, afectando tanto al individuo como a su entorno (Hermida Moreno, 2024). A pesar de los avances en la detección del Burnout mediante inteligencia artificial, falta un sistema integral que combine múltiples fuentes de datos y proporcione alertas tempranas para la prevención (Vorecol, 2024).

Este proyecto busca desarrollar un sistema predictivo multimodal que detecte signos de Burnout y envíe alertas personalizadas para intervenciones tempranas, mejorando así el bienestar laboral y reduciendo el riesgo de abandono del empleo (Escobar, 2023). La implementación de soluciones basadas en IA ha demostrado ser efectiva en la reducción del Burnout, mejorando la satisfacción laboral y disminuyendo la rotación de personal (Vorecol, 2024).

Pregunta De Investigación

¿Cómo puede un sistema predictivo multimodal que integra análisis de sentimientos, comportamiento laboral y expresiones faciales, junto con alertas tempranas personalizadas, mejorar la detección y prevención del Síndrome de Burnout en entornos laborales?

Objetivos

Objetivo General

Desarrollar un sistema predictivo multimodal que integre análisis de sentimientos, comportamiento laboral y expresiones faciales para detectar signos de Burnout en entornos laborales y enviar alertas tempranas personalizadas para la prevención.

Objetivos Específicos

- Analizar el estado del arte en detección de Burnout mediante técnicas multimodales, identificando variables clave, métodos de recolección de datos y mejores prácticas en el ámbito laboral.
- Diseñar un modelo de aprendizaje automático que combine múltiples fuentes de datos (textos, comportamiento laboral, expresiones faciales) para predecir el riesgo de Burnout en empleados.
- Implementar un sistema de alertas tempranas que envíe notificaciones personalizadas a empleados y departamentos de RRHH basadas en los resultados del modelo predictivo.
- Evaluar la efectividad del sistema integral en la detección temprana y prevención del Burnout, comparando los resultados con métodos tradicionales de detección.

Justificación

El desarrollo del proyecto "Sistema Predictivo Multimodal para la Detección Temprana y Prevención del Síndrome de Burnout en Entornos Laborales" es altamente relevante y beneficioso. Este proyecto ofrece varias mejoras significativas sobre otros proyectos existentes. En primer lugar, la integración de múltiples fuentes de datos, como análisis de sentimientos, comportamiento laboral y expresiones faciales, permite una detección más precisa del Burnout comparada con métodos que solo utilizan un tipo de dato. El enfoque multimodal es crucial porque permite capturar tanto información intra-modal como inter-modal, lo que es esencial para abordar la complejidad del Burnout. Además, las detecciones faciales son particularmente valiosas ya que las expresiones faciales pueden revelar cambios emocionales sutiles que indican estrés o agotamiento, como se ha observado en estudios sobre reconocimiento de emociones faciales en personas con Burnout, quienes tienden a tener dificultades para reconocer emociones negativas (Mascha Kurpicz-Briki, 2024). La tecnología de IA, especialmente el procesamiento del lenguaje natural (NLP), ha demostrado ser efectiva en la detección de Burnout al analizar textos y comunicaciones de empleados (The Brussels Times, 2022).

Este proyecto se alinea con el propósito del programa de maestría en ciencias de datos al aplicar técnicas de Machine Learning para resolver un problema real. La investigación ofrece relevancia práctica al proporcionar herramientas para la detección temprana del Burnout, y valor teórico al explorar la integración de múltiples fuentes de datos para mejorar la precisión en la detección. Además, su utilidad metodológica radica en la combinación de análisis de

sentimientos, comportamiento laboral y expresiones faciales, lo que enriquece el campo de la detección de Burnout. Una vez finalizado, este proyecto podría ser adoptado por diversas organizaciones para mejorar el bienestar laboral y reducir el riesgo de Burnout, alineándose con las tendencias actuales de utilizar IA para prevenir el Burnout y mejorar la productividad laboral (Navarro, 2024).

Marco Teórico

El síndrome de burnout ha sido conceptualizado como una respuesta al estrés laboral crónico, y se manifiesta principalmente en profesiones que implican un contacto frecuente con otras personas, como las del sector de servicios, salud y educación (Guevara Cazar, 2012) (Velázquez, 2009). El término fue introducido por Freudenberger en 1974, quien lo describió como una sensación de fracaso y agotamiento provocada por una sobrecarga de demandas emocionales, físicas y espirituales en el entorno laboral (Abdelhadi, Mohammed, Babikir, Bedri, & Abdelhadi, 2025).

El síndrome se configura como una respuesta psicológica prolongada frente al estrés interpersonal crónico en el trabajo, y tiene implicaciones críticas, especialmente en sectores con alta exigencia emocional, como la atención en salud mental. Su comprensión demanda un análisis multidimensional que considere componentes emocionales, actitudinales y contextuales.

El presente marco teórico expone los conceptos, modelos y fundamentos necesarios para comprender el síndrome de burnout y su relación con los sistemas predictivos multimodales. A diferencia de los antecedentes investigativos, que presentan estudios previos comparables, este apartado se centra en la fundamentación conceptual que respalda la metodología de la investigación, incluyendo la definición del burnout, sus dimensiones, factores de riesgo, consecuencias, instrumentos de evaluación y estrategias de prevención e intervención.

Definición, Conceptualización y Dimensiones del Burnout

El síndrome de burnout (BOS) es un trastorno psicológico que surge como respuesta prolongada ante estresores crónicos en el entorno laboral, especialmente en profesiones que exigen una interacción constante con otras personas (Guevara Cazar, 2012). Después de ser introducido por Freudenberger en 1974 , Maslach y Jackson (1981) consolidaron el concepto mediante un modelo tridimensional, ampliamente validado a nivel internacional a través del Maslach Burnout Inventory (MBI) (Oviedo C & Villamizar F, 2023) .

Según esta perspectiva, el burnout se caracteriza por tres dimensiones principales:

- Agotamiento emocional (EE): Sensación persistente de cansancio extremo y falta de energía para afrontar las demandas laborales. Constituye el núcleo del síndrome y representa el agotamiento de los recursos emocionales del trabajador (Guevara Cazar, 2012)
- Despersonalización (DP) o cinismo: Actitudes negativas, distantes o frías hacia los beneficiarios del trabajo (pacientes, usuarios, estudiantes), como mecanismo defensivo ante la sobrecarga emocional. Este componente refleja una forma de distanciamiento interpersonal que puede traducirse en expresiones impersonales o cínicas (Guevara Cazar, 2012) (Loterio M & all, 2020).

- Baja realización personal (RP): Sentimientos de ineficacia, fracaso y disminución de la autoestima en relación con los logros profesionales. Se manifiesta como una percepción negativa del impacto del propio trabajo y una menor valoración del desempeño (Karine & Giraldo, 2015).

La Organización Mundial de la Salud (OMS) reconoció formalmente el burnout como un factor de riesgo laboral en el año 2000, y en 2019 lo incorporó a la Clasificación Internacional de Enfermedades (CIE-11) como un "síndrome de desgaste ocupacional", resultado del estrés crónico en el trabajo que no ha sido gestionado adecuadamente (Apiquian, 2007). Esta inclusión ha reforzado su relevancia como problema de salud pública, con implicaciones en la motivación, el desempeño y el bienestar de los trabajadores.

El modelo tridimensional del burnout, validado internacionalmente mediante el MBI, ha demostrado consistencia en más de 30 idiomas y contextos laborales. Esta solidez conceptual y empírica ha permitido su aplicación en diversos estudios e intervenciones orientadas a la prevención y tratamiento del síndrome.

Diferenciación entre Burnout y Depresión

Aunque el burnout comparte síntomas con trastornos depresivos (ej. fatiga), se distingue por (Maslach & Leiter, 2016):

- Especificidad contextual: Limitado al ámbito laboral.

- Componente actitudinal: El cinismo como respuesta a entornos laborales disfuncionales.
- Correlatos fisiológicos: Mayor asociación con marcadores inflamatorios (proteína C-reactiva) y riesgos cardiovasculares.

Esta distinción es crucial para sistemas de detección temprana, ya que requiere diferenciar entre señales laborales (ej. patrones de comunicación negativa) y síntomas generalizados de salud mental.

Evolución Histórica y Contextualización

Orígenes y Desarrollo Conceptual

- **1974**: Freudenberger identificó el burnout en trabajadores de salud mental, vinculándolo al agotamiento por exigencias emocionales excesivas (Guevara Cazar, 2012).
- **1981**: Maslach y Jackson propusieron el Maslach Burnout Inventory (MBI), herramienta clave para medir las tres dimensiones del síndrome.
- **1990s**: Surgieron modelos alternativos, como el procesual de Leiter y Maslach (1988), que enfatiza el desequilibrio entre demandas laborales y recursos personales (Guevara Cazar, 2012).
- **2000s**: Se amplió el estudio a sectores más allá de los servicios, incluyendo educación, ingeniería y tecnología (Oviedo C & Villamizar F, 2023).

Perspectivas Teóricas

- **Clínica:** Considera el burnout como un estado resultante del estrés laboral acumulado, con manifestaciones físicas y psicológicas (Guevara Cazar, 2012).
- **Psicosocial:** Lo entiende como un proceso dinámico influido por factores organizacionales (cultura, apoyo social) e individuales (personalidad, estrategias de afrontamiento) (Acosta & Taline, 2020).

Modelos y Teorías Explicativas

Diversos modelos teóricos han sido propuestos para explicar el desarrollo y la manifestación del síndrome de burnout. A continuación, se describen los más relevantes:

- Modelo Tridimensional de Maslach

Este modelo, ampliamente aceptado, plantea que el burnout surge de la interacción entre demandas emocionales intensas y recursos personales insuficientes para afrontarlas, especialmente en ocupaciones que implican atención directa a personas (Loterio M & all, 2020). Se estructura en tres dimensiones: agotamiento emocional, despersonalización y baja realización personal.

- Modelo de Fases de Golembiewski, Munzenrider y Carter (1984)

Este modelo propone una progresión secuencial del burnout en fases, comenzando por el agotamiento emocional, seguido de la despersonalización, y concluyendo con una disminución en la realización personal (Karine & Giraldo, 2015).

- Modelo de Winnubst (1993)

Winnubst enfatiza el papel de factores organizacionales en el desarrollo del burnout. La estructura organizacional, el clima laboral y el nivel de apoyo social son determinantes. La falta de apoyo y un ambiente laboral negativo aumentan significativamente el riesgo de burnout.

- Modelo de Fases de Golembiewski (1984)

Propone una evolución del burnout a lo largo de ocho etapas, comenzando con el agotamiento emocional, seguido por la despersonalización y finalizando con la reducción de la realización personal (Guevara Cazar, 2012).

- Modelo de Farber (1991)

Farber describe seis etapas en el desarrollo del burnout:

- ✓ Entusiasmo inicial.
- ✓ Frustración frente a los estresores laborales.
- ✓ Desequilibrio entre esfuerzo y recompensa.
- ✓ Abandono del compromiso con el trabajo.
- ✓ Aparición de síntomas físicos y emocionales.
- ✓ Agotamiento total y negligencia en el desempeño (Oviedo C & Villamizar F, 2023).

- Modelo Procesual de Leiter y Maslach (1988)

Este modelo plantea que el burnout comienza con un desequilibrio entre las demandas organizacionales y los recursos personales. Esto genera agotamiento emocional, que a su vez da lugar a la despersonalización y finalmente, a la baja realización personal (Guevara Cazar, 2012).

- Modelo Transaccional de Estrés y Afrontamiento

El "Modelo Transaccional de Estrés y Afrontamiento" de Lazarus (1991) proporciona un marco conceptual para entender cómo los estresores laborales afectan el bienestar psicológico.

Este modelo sostiene que:

- ✓ La respuesta al estrés depende de la interpretación subjetiva del estresor.
- ✓ Dicha interpretación desencadena una respuesta emocional específica.
- ✓ La evaluación primaria implica valorar la relevancia del evento para los objetivos, valores o necesidades personales.
- ✓ Solo los eventos considerados relevantes generan respuestas emocionales.
- ✓ La evaluación secundaria considera los recursos percibidos para afrontar el evento, influyendo en la intensidad de la emoción.

Dos aspectos clave de este modelo son:

- ✓ La intensidad del estrés depende de la importancia del valor o meta amenazada.
- ✓ El modelo se centra en la experiencia prolongada de emociones discretas como predictores del bienestar psicológico.

Factores de Riesgo Asociados

Entre los principales factores que favorecen el desarrollo del burnout se encuentran la sobrecarga de trabajo, la ambigüedad y el conflicto de roles, la falta de apoyo social, la escasa autonomía laboral, el bajo reconocimiento, los problemas de sueño y las estrategias de afrontamiento poco adaptativas. Estos factores no actúan de forma aislada, sino que interactúan con las condiciones organizacionales y con los recursos personales disponibles para afrontar las demandas del trabajo. Por ello, el burnout debe comprenderse como un fenómeno multicausal en

el que confluyen variables individuales, organizacionales y sectoriales (Oviedo C & Villamizar F, 2023). Las consecuencias de este síndrome afectan tanto al individuo generando enfermedades físicas y mentales, insatisfacción laboral y absentismo como a la organización, provocando baja productividad, alta rotación de personal y deterioro del clima laboral (Guevara Cazar, 2012) (Apiquian, 2007).

Los factores individuales comprenden características personales o condiciones que pueden aumentar la vulnerabilidad frente al estrés laboral crónico, tales como perfeccionismo, altas expectativas laborales, baja resiliencia, problemas de sueño, consumo problemático de alcohol, bajo apoyo social y estrategias de afrontamiento pasivas. Estos elementos pueden reducir la capacidad de recuperación física y emocional frente a demandas laborales sostenidas, especialmente cuando la persona no cuenta con recursos suficientes de afrontamiento o apoyo social pasivos (Oviedo C & Villamizar F, 2023) , (Bizuneh, Markos Woldeamayyat, Lucero, & Markos, 2025)

Los factores organizacionales se relacionan con la sobrecarga laboral, la falta de autonomía, el escaso reconocimiento, los turnos extensos, la comunicación deficiente, los conflictos interpersonales, el clima laboral negativo y la dificultad para establecer límites entre la vida personal y laboral. Estas condiciones pueden incrementar la exposición prolongada al estrés y favorecer la aparición de agotamiento emocional, despersonalización y baja realización personal (Alzate, 2021) (Acosta & Taline, 2020) (Garcéz & García, 2023) (Igartua, 2024).

Por último, los factores sectoriales hacen referencia a características propias de ciertas ocupaciones, como el contacto permanente con usuarios, pacientes o estudiantes, la presión por resultados, la responsabilidad sobre terceros y la exigencia de disponibilidad constante. En sectores como salud, educación y tecnología, estas condiciones pueden generar demandas emocionales, cognitivas y organizacionales sostenidas, lo que justifica la necesidad de estrategias de detección temprana y prevención del burnout en entornos laborales diversos (Alzate, 2021) (Acosta & Taline, 2020) (Sabori & Hidalgo, 2014).

Presión Laboral como Factor Determinante del Burnout

La presión laboral se define como el grado en que los profesionales deben continuar sus tareas fuera del horario de trabajo, incluyendo noches y fines de semana, o cuando la jornada diaria resulta tan exigente que apenas deja tiempo suficiente para la recuperación física y emocional (Skaalvik & Skaalvik, 2009). Desde una perspectiva teórica, esta presión constituye un factor relevante en la comprensión del burnout, ya que prolonga la exposición del trabajador a demandas laborales intensas, limita los tiempos de descanso y reduce la posibilidad de recuperación frente al estrés ocupacional. En este sentido, la presión laboral puede relacionarse con los componentes centrales del burnout, especialmente con el agotamiento emocional, la despersonalización y la disminución de la realización personal (Dehne, Roorda, Koomen, & Zee, 2024).

El Rol Mediador de las Relaciones Interpersonales en el Burnout

Las relaciones interpersonales en el entorno de trabajo pueden comprenderse como un elemento mediador entre la presión laboral y el burnout. Desde esta perspectiva, la calidad de las

interacciones sociales en el ámbito laboral puede mitigar o agravar los efectos de la presión sobre la salud mental del trabajador. Cuando existen apoyo social, comunicación efectiva y relaciones colaborativas, el trabajador puede contar con mayores recursos para afrontar las demandas laborales. Por el contrario, los conflictos interpersonales, la baja cohesión del equipo o la ausencia de apoyo pueden intensificar el agotamiento emocional y favorecer el distanciamiento actitudinal propio del burnout.

Contextos laborales asociados al burnout

El burnout ha sido estudiado principalmente en sectores caracterizados por alta demanda emocional, contacto interpersonal sostenido, presión por resultados y responsabilidad sobre terceros, como salud, educación, servicios sociales y organizaciones con exigencias continuas de productividad. Desde el punto de vista teórico, estos contextos permiten comprender que el síndrome no depende únicamente de características individuales, sino de la interacción entre demandas laborales, recursos disponibles, apoyo organizacional, autonomía, reconocimiento y condiciones psicosociales del trabajo (Alzate, 2021) (Acosta & Taline, 2020) (Igartua, 2024) (Sabori & Hidalgo, 2014).

En el sector salud, la atención permanente a pacientes, la presión asistencial, los recursos limitados y la exposición a situaciones emocionalmente exigentes pueden favorecer procesos de agotamiento emocional y distanciamiento actitudinal (Alzate, 2021) (Acosta & Taline, 2020). En el sector educativo, la carga administrativa, la presión por resultados y la interacción constante con estudiantes o familias pueden contribuir a la reducción de la realización personal (Sabori & Hidalgo, 2014). En contextos tecnológicos y organizacionales altamente competitivos, la

innovación continua, la disponibilidad permanente y las jornadas prolongadas pueden aumentar la exposición a estrés laboral crónico (Igartua, 2024).

Las diferencias culturales, económicas y organizacionales también influyen en la forma en que el burnout se manifiesta y se gestiona. Por esta razón, su análisis requiere considerar el entorno laboral específico, las condiciones de protección social, la estabilidad del empleo, el estilo de liderazgo y las prácticas institucionales de prevención. En contextos latinoamericanos, factores como la informalidad laboral, los bajos salarios y la inestabilidad económica pueden agravar las condiciones psicosociales asociadas al desgaste ocupacional y dificultar su prevención oportuna (Alzate, 2021) (Garcéz & García, 2023). Esta comprensión contextual respalda la pertinencia de sistemas de detección temprana que no se limiten a una única fuente de información, sino que integren señales complementarias para apoyar la toma de decisiones preventivas.

Consecuencias del Burnout

Las consecuencias del burnout pueden comprenderse en tres niveles interrelacionados: individual, social y organizacional. A nivel individual, el síndrome puede manifestarse mediante fatiga persistente, cefaleas, alteraciones del sueño, molestias musculoesqueléticas, irritabilidad, desmotivación, ansiedad, tristeza, disminución de la energía y percepción de ineffectividad. A nivel social, puede afectar las relaciones familiares y laborales debido al aislamiento, la menor tolerancia interpersonal y el deterioro del vínculo con usuarios, pacientes, estudiantes, compañeros o superiores. A nivel organizacional, puede relacionarse con ausentismo, presentismo, rotación, reducción del desempeño, deterioro del clima laboral y aumento de costos

asociados a incapacidades, reemplazos o disminución de la productividad (Oviedo C & Villamizar F, 2023) (Sabori & Hidalgo, 2014) (Acosta & Taline, 2020) (Garcéz & García, 2023) (Rodríguez & De Rivas, 2011) (Alzate, 2021).

Consecuencias físicas del burnout

El burnout puede manifestarse en el plano físico debido a la exposición prolongada a condiciones de estrés laboral crónico. Desde una perspectiva teórica, el agotamiento sostenido no solo afecta la percepción subjetiva de bienestar, sino que también puede relacionarse con alteraciones fisiológicas asociadas a la activación persistente de los sistemas de respuesta al estrés. Entre las consecuencias físicas descritas en la literatura se encuentran cefaleas, fatiga persistente, trastornos del sueño, molestias musculoesqueléticas, alteraciones metabólicas y mayor vulnerabilidad a problemas cardiovasculares (Oviedo C & Villamizar F, 2023) (Sabori & Hidalgo, 2014) (Alviery, y otros, 2017).

Estos efectos pueden explicarse, en parte, por mecanismos neuroendocrinos asociados a la respuesta fisiológica al estrés crónico. Uno de los principales mecanismos es la alteración del eje hipotalámico-hipofisario-adrenal (HPA), sistema encargado de regular la respuesta del organismo frente al estrés mediante la liberación de hormonas como el cortisol. Cuando una persona se expone de manera prolongada a demandas laborales intensas, este eje puede mantenerse activado durante periodos extensos, generando desregulación hormonal, fatiga fisiológica y mayor vulnerabilidad a procesos inflamatorios. De forma complementaria, la activación simpática prolongada (relacionada con el estado de alerta del organismo) puede contribuir al aumento de la tensión cardiovascular, alteraciones del sueño y desgaste físico. Por

esta razón, el burnout no solo tiene implicaciones psicológicas, sino también posibles consecuencias físicas asociadas al mantenimiento sostenido de la respuesta de estrés (Alviery, y otros, 2017).

Impacto psicológico y salud mental

En el plano psicológico, el burnout puede relacionarse con ansiedad, estados depresivos, irritabilidad, pérdida de motivación, dificultad para concentrarse, sensación de fracaso, ideación suicida y disminución del compromiso laboral. Aunque comparte algunas manifestaciones con trastornos depresivos, debe analizarse de manera diferenciada porque su origen y expresión están estrechamente vinculados al contexto laboral. Esta distinción es relevante para la presente investigación, dado que el sistema propuesto busca identificar señales de riesgo ocupacional y no realizar diagnósticos clínicos (Acosta & Taline, 2020)

Impacto social

En el plano social, el burnout puede afectar la calidad de las relaciones familiares, laborales e interpersonales. El agotamiento emocional, la irritabilidad y el distanciamiento actitudinal pueden favorecer conflictos familiares, aislamiento social y deterioro en la interacción con compañeros, usuarios, pacientes, estudiantes o superiores. Esta dimensión es importante porque evidencia que el síndrome no solo afecta el desempeño individual, sino también los vínculos que sostienen la vida laboral y personal del trabajador (Garcéz & García, 2023) (Rodríguez & De Rivas, 2011).

Impacto organizacional

En las organizaciones, el burnout puede traducirse en ausentismo, rotación, presentismo, disminución del desempeño, deterioro del clima laboral y aumento de costos asociados a reemplazos, incapacidades o pérdida de productividad. El ausentismo se refiere a la ausencia del trabajador en sus jornadas laborales; la rotación corresponde a la salida o reemplazo frecuente de empleados; y el presentismo describe la situación en la que una persona asiste a trabajar, pero con disminución significativa de su rendimiento debido a malestar físico, emocional o psicológico. Estas consecuencias justifican la pertinencia de sistemas de apoyo orientados a la detección temprana y a la activación de alertas preventivas, siempre como complemento de la valoración humana y organizacional (Alzate, 2021) (Garcéz & García, 2023) (Apiquian, 2007).

Hipótesis

El presente capítulo expone las hipótesis que guían esta investigación, formuladas a partir del análisis del marco teórico y la pregunta central del estudio. Las hipótesis propuestas buscan establecer relaciones causales y predictivas entre variables asociadas al estrés laboral crónico y la detección temprana del Síndrome de Burnout mediante herramientas de inteligencia artificial. Su planteamiento responde a la necesidad de avanzar desde enfoques diagnósticos tradicionales hacia modelos preventivos y automatizados, alineados con los desarrollos recientes en psicometría y análisis de datos multimodales. A continuación, se presentan la hipótesis primaria y secundaria, junto con su justificación teórica, metodológica y su vinculación con el marco conceptual.

Hipótesis Primaria

H1: La integración multimodal de análisis de sentimientos en textos (X1), patrones de comportamiento laboral (X2) y detección de expresiones faciales asociadas a estrés (X3) predice significativamente el riesgo de Síndrome de Burnout (Y1) en empleados, con una precisión superior al 85% comparado con métodos unimodales, según el modelo tridimensional de Maslach (agotamiento emocional, despersonalización, baja realización personal) (Tamburrino, s.f.) (Fórmica, Muñoz, & Rojas, 2015)

Justificación teórica:

Se fundamenta en el modelo de estrés laboral crónico de Lazarus (1991) (Rhein, 2022), donde la interacción prolongada entre demandas organizacionales (sobrecarga laboral,

falta de autonomía) y respuestas emocionales (capturadas por X1 y X3) genera agotamiento acumulativo (Etecé, Equipo editorial, 2015).

El componente actitudinal de la despersonalización (Y1b) se correlaciona con patrones de comunicación negativa (X1b: polaridad < -0.5 en NLP) (Universidad Excelsior, 2023) (Bittar, 2008), mientras que la baja realización personal (Y1c) se asocia con disminución del 30% en métricas de productividad (X2a: horas activas/productividad) (Rivas, 2022) (Godoy, 2025).

Hipótesis Secundaria (Causal)

H2: La implementación de un sistema de alertas tempranas basado en Inteligencia Artificial (X4) reduce la incidencia de Burnout (Y1) en un 40% a los 6 meses mediante intervenciones personalizadas (flexibilidad horaria, capacitación en gestión emocional), mediado por la mejora en percepción de apoyo organizacional (M1: $\beta=0.72$ $p<0.01$) (Patlán, 2013).

Relación con el marco teórico:

Alineado con el modelo de recursos y demandas laborales (JD-R), donde las alertas (X4) actúan como mecanismo de balance al incrementar recursos psicológicos (autonomía, retroalimentación positiva) (Rhein, 2022) (Galliussi, 2020).

La efectividad se sustenta en estudios prospectivos que demuestran que intervenciones tempranas reducen el agotamiento emocional (Y1a) en profesionales con carga horaria $>45\text{h/semana}$ (OR=0.58) (Tamburrino, s.f.) (Godoy, 2025).

Fundamentación Metodológica

Variables vinculadas:

Independientes: X1 (análisis de sentimientos), X2 (patrones laborales), X3 (expresiones faciales), X4 (alertas).

Dependientes: Y1 (Burnout), Y2 (efectividad del sistema).

Mediadoras: M1 (apoyo organizacional).

Nexo con la pregunta de investigación:

Ambas hipótesis responden al cómo planteado en la pregunta central:

H1 explica el mecanismo de detección mediante integración multimodal.

H2 aborda la prevención mediante acciones derivadas del sistema (Ospina H, 2024).

Originalidad:

Combina el modelo tridimensional de Maslach con técnicas de Inteligencia Artificial explicable (XAI), superando limitaciones de estudios previos que solo usaban encuestas (Fórmica, Muñoz, & Rojas, 2015) (Rhein, 2022).

Propone un enfoque preventivo (no solo diagnóstico) al vincular alertas con políticas organizacionales (Galliussi, 2020).

Estas hipótesis cumplen con los criterios de:

Testabilidad: Medibles mediante MBI (Maslach Burnout Inventory), NLP (Procesamiento del Lenguaje Natural) y modelos de ML (Aprendizaje Automático) (Universidad Excelsior, 2023).

Replicabilidad: Protocolos estandarizados en Azure Face API y escalas validadas (Bittar, 2008) (Rivas, 2022).

Alineación teórica: Derivadas directamente del marco conceptual sobre estrés laboral crónico y modelos de intervención organizacional (Tamburrino, s.f.) (Rhein, 2022).

Variables

A continuación, se definen las variables clave que serán medidas en la investigación, las cuales permiten analizar los factores asociados al Síndrome de Burnout y su detección mediante un sistema predictivo multimodal. Las variables seleccionadas están alineadas con los objetivos del estudio y abarcan dimensiones relacionadas con el análisis de sentimientos, patrones de comportamiento laboral, expresiones faciales y la efectividad del sistema de alertas. Cada variable se presenta con su definición conceptual y operacional con el propósito de garantizar claridad en su medición y relevancia dentro del contexto de la presente investigación. Adicional, se clasifica cada variable según su rol en el modelo predictivo (dependiente o independiente) y su nivel de medición, destacando la interdependencia entre ellas para obtener resultados integrales.

Variable 1. Riesgo de Burnout

Definición conceptual:

El riesgo de Burnout es un constructo multidimensional que engloba agotamiento emocional, despersonalización y reducción de la realización personal en el trabajo, según el modelo tridimensional de Maslach (Wikipedia, mayo, 2025), (Alexandra M Shishkova, 2022).

Definición operacional:

- **Medición:**

- ✓ Escala MBI (Maslach Burnout Inventory): Se utilizan los valores de las subescalas de agotamiento emocional, despersonalización y realización

personal, de acuerdo con la versión correspondiente del MBI, (Maslach C. , Jackson, Schaufeli, & Schwab, 2025).

- ✓ Modelo predictivo: El sistema asigna una probabilidad de riesgo de Burnout a partir de los datos multimodales; se considera riesgo alto cuando la probabilidad es igual o superior al 70%, (Latus, 2023).

- **Clasificación:**

- ✓ Variable dependiente.
- ✓ Nivel de medición: Escala de intervalo.

Variable 2. Análisis de sentimientos (datos textuales)

Definición conceptual:

El análisis de sentimientos se refiere a la evaluación del tono emocional en comunicaciones escritas, asociado a estados de estrés o frustración, mediante técnicas de procesamiento de lenguaje natural (NLP), (CorestratAI, 2024).

Definición operacional:

- **Medición:**

- ✓ Procesamiento de Lenguaje Natural (NLP): Se emplean modelos BERT o RoBERTa para clasificar emociones en textos de empleados, (Walid Boussou, 2024).
- ✓ Métrica: Se calcula el porcentaje de mensajes con polaridad negativa por semana; se considera relevante si supera el 30% del total de mensajes analizados.

- **Clasificación:**

- ✓ Variable independiente.
- ✓ Nivel de medición: Razón.

Variable 3. Patrones de comportamiento laboral

Definición conceptual:

Incluye indicadores de productividad e interacción, como horas trabajadas, cumplimiento de plazos y uso de herramientas digitales, que pueden estar relacionados con el desarrollo de Burnout, (Summers, 2024).

Definición operacional:

- **Medición:**

- ✓ Registros digitales: Se analiza el tiempo activo en sistemas (>10 h/día), retrasos en entregas (≥ 3 días) y otros indicadores de desempeño, (John Brownridge, 2024)
- ✓ Índice de productividad: Se utiliza una escala de 0 a 100, calculada a partir de los registros de actividad y cumplimiento de objetivos.

- **Clasificación:**

- ✓ Variable independiente.
- ✓ Nivel de medición: Intervalo.

Variable 4. Expresiones faciales

Definición conceptual:

Las expresiones faciales, especialmente las microexpresiones asociadas a estrés, pueden ser capturadas y analizadas mediante sistemas de reconocimiento facial y análisis de emociones, (datalab.io, 2023).

Definición operacional:

- **Medición:**
 - ✓ OpenCV/Azure Face API: Se detectan unidades de acción facial (por ejemplo, para ceño fruncido) y se cuantifica su frecuencia durante la jornada laboral, (Farley, 2025).
 - ✓ Métrica: Se considera relevante una frecuencia igual o superior a 15 veces por hora.
- **Clasificación:**
 - ✓ Variable independiente.
 - ✓ Nivel de medición: Razón.

Variable 5. Efectividad del sistema de alertas

Definición conceptual:

Se refiere a la capacidad del sistema para reducir incidentes de Burnout mediante la emisión de alertas tempranas y personalizadas que permitan intervenciones oportunas, (Slate Safety, 2025).

Definición operacional:

- **Medición:**

- ✓ Tasa de reducción: Se calcula la diferencia porcentual en la incidencia de Burnout antes y después de la implementación del sistema de alertas (por ejemplo, una reducción del 30% en seis meses), (Interlogos, 2024), .
- ✓ Encuestas de satisfacción: Se aplican escalas tipo Likert (1-5) para evaluar la percepción de utilidad del sistema por parte de empleados y responsables de RRHH, (Slate Safety, 2025).

- **Clasificación:**

- ✓ Variable dependiente.
- ✓ Nivel de medición: Intervalo.

Metodología

Enfoque de la investigación

El presente estudio adopta un enfoque mixto, integrando métodos cuantitativos y cualitativos para abordar la complejidad del Síndrome de Burnout en entornos laborales. El enfoque cuantitativo permite medir variables objetivas como el análisis de sentimientos, patrones de comportamiento laboral y expresiones faciales, mientras que el enfoque cualitativo complementa la interpretación de los resultados y la comprensión de las experiencias de los participantes (Creswell, 2014) (Hernández Sampieri, 2014). Esta combinación es especialmente pertinente en investigaciones sobre salud mental y tecnología, ya que facilita una visión integral del fenómeno y la validación de los hallazgos desde diferentes perspectivas (Flick, 2018).

Diseño y tipo de estudio

El diseño de la investigación es no experimental, transversal y descriptivo-correlacional. No se manipulan variables, sino que se observan y analizan en su contexto natural, lo que es adecuado para estudios en los que se busca identificar relaciones entre variables sin intervención directa (Kerlinger, 2002) (Montero, 2007). El carácter transversal implica que la recolección de datos se realiza en un solo momento, permitiendo obtener una fotografía del estado del Burnout y sus factores asociados en la población objetivo. El estudio es descriptivo-correlacional porque describe las características de la muestra y explora las relaciones entre el riesgo de Burnout y las variables predictoras, como el análisis de sentimientos, el comportamiento laboral y las expresiones faciales (Schaufeli, 2009).

Fases Metodológicas por Objetivo Específico

Objetivo Específico 1: Analizar el estado del arte en detección de Burnout mediante técnicas multimodales, identificando variables clave, métodos de recolección de datos y mejores prácticas en el ámbito laboral.

Fase 1.1: Revisión sistemática de literatura

- Búsqueda en bases de datos científicas (Scopus, PubMed, Web of Science) de estudios recientes sobre detección de Burnout con técnicas multimodales, priorizando artículos que integren análisis de sentimientos, comportamiento laboral y expresiones faciales. (Matinez Perez, 2010)
- Extracción de variables clave, métodos de recolección de datos y mejores prácticas reportadas en la literatura, con énfasis en el uso del Maslach Burnout Inventory (MBI) como instrumento de referencia (Martins, 2025).

Fase 1.2: Análisis comparativo

- Comparación de métodos y resultados entre diferentes estudios.
- Identificación de buenas prácticas y limitaciones en la literatura.
- Elaboración de un marco conceptual sobre las variables y fuentes de datos más relevantes para la detección multimodal de Burnout.

Objetivo Específico 2: Diseñar un modelo de aprendizaje automático que combine múltiples fuentes de datos (textos, comportamiento laboral, expresiones faciales) para predecir el riesgo de Burnout en empleados.

Fase 2.1: Definición y selección de variables

- Selección de variables predictoras basadas en el análisis del estado del arte (análisis de sentimientos (NPL), patrones de comportamiento laboral, expresiones faciales) (Rojas B, 2020).

Fase 2.2: Diseño del modelo predictivo

- Selección de algoritmos de aprendizaje automático apropiados (por ejemplo, Random Forest, SVM, redes neuronales, modelos multimodales).
- Integración de las diferentes fuentes de datos en un pipeline de procesamiento unificado (Saborio & Murillo, 2015).

Fase 2.3: Preparación y procesamiento de datos

- Recolección y preprocesamiento de datos textuales, registros digitales y capturas de expresiones faciales.
- Limpieza, transformación y normalización de los datos para su uso en el modelo.

Fase 2.4: Entrenamiento y validación del modelo

- División de los datos en conjuntos de entrenamiento y prueba.
- Entrenamiento del modelo y ajuste de hiperparámetros.
- Validación cruzada y evaluación de métricas de desempeño (precisión, recall, F1-score, ROC-AUC) (Saborio & Murillo, 2015).

Objetivo Específico 3: Implementar un sistema de alertas tempranas que envíe notificaciones personalizadas a empleados y departamentos de RRHH basadas en los resultados del modelo predictivo.

Fase 3.1: Diseño del sistema de alertas

- Definición de criterios y umbrales para la generación de alertas (por ejemplo, probabilidad de Burnout $\geq 70\%$).
- Desarrollo de la lógica de personalización de alertas según perfil de riesgo y contexto laboral.

Fase 3.2: Integración tecnológica

- Implementación del sistema de alertas en la plataforma tecnológica seleccionada (aplicación web, móvil, correo electrónico, etc.).
- Integración del modelo predictivo con el módulo de notificaciones.

Fase 3.3: Pruebas piloto y ajustes

- Realización de pruebas piloto con un grupo reducido de usuarios (Rojas B, 2020).
- Recopilación de retroalimentación y ajuste de la lógica de alertas y la interfaz de usuario.

Objetivo Específico 4: Evaluar la efectividad del sistema integral en la detección temprana y prevención del Burnout, comparando los resultados con métodos tradicionales de detección.

Fase 4.1: Diseño del protocolo de evaluación

- Definición de indicadores de efectividad (reducción de casos de Burnout, satisfacción de usuarios, precisión del sistema, etc.) (Palma, Marchant, Vera, & Larraín, 2025).
- Selección de métodos tradicionales de detección (por ejemplo, solo MBI) para comparación (Martins, 2025), (Saborio & Murillo, 2015).

Fase 4.2: Implementación del estudio comparativo

- Aplicación del sistema predictivo y de los métodos tradicionales en la muestra seleccionada.
- Recolección de datos antes y después de la implementación del sistema de alertas.

Fase 4.3: Análisis de resultados

- Análisis estadístico comparativo de la incidencia de Burnout y otros indicadores clave.
- Evaluación cualitativa mediante encuestas y entrevistas a usuarios y responsables de RRHH.

- Discusión de hallazgos y recomendaciones para la mejora del sistema (Palma, Marchant, Vera, & Larraín, 2025).

Población y muestra

La población objetivo está compuesta por empleados de empresas del sector servicios en entornos urbanos. La muestra se selecciona mediante muestreo no probabilístico por conveniencia, una estrategia común en estudios exploratorios donde la accesibilidad y la disposición de los participantes son factores determinantes, especialmente cuando se requiere la recolección de datos multimodales y existe una logística compleja. Los criterios de inclusión son: antigüedad laboral mínima de seis meses y consentimiento informado para participar en el estudio (Martínez-Salgado, 2012). Se excluyen empleados en periodo de prueba, en licencia prolongada o con diagnóstico previo de trastornos psiquiátricos graves, para evitar sesgos en la evaluación del síndrome de burnout.

El tamaño de la muestra se determina en función de la disponibilidad de participantes y la viabilidad de la recolección de datos multimodales, recomendándose un mínimo de 100 sujetos para garantizar la validez estadística (Polit, 2017). Se procurará incluir participantes de diferentes cargos y áreas funcionales para mejorar la diversidad y la aproximación a la representatividad de la población objetivo. Se recopilarán variables sociodemográficas y

laborales como edad, género, cargo, área y antigüedad, ya que estos factores pueden influir en la prevalencia y manifestación del síndrome de burnout.

Instrumento de medición y validación

El instrumento principal de medición es el Maslach Burnout Inventory (MBI), ampliamente validado en estudios internacionales y adaptado a diferentes contextos laborales y culturales, mostrando alta confiabilidad y validez factorial, con valores de alfa de Cronbach reportados entre 0.70 y 0.90 según la dimensión evaluada (Maslach C. , Jackson, Schaufeli, & Schwab, 2025) (Schaufeli, 2009). Para garantizar la pertinencia cultural y lingüística, se emplea la versión adaptada al contexto local, siguiendo recomendaciones metodológicas para la adaptación de instrumentos psicométricos (Schaufeli, 2009) (Cabezas, Aguirre, Cabezas, & Ceballos, 2022).

La validación de los instrumentos incluye:

Consistencia interna: Se evalúa mediante el coeficiente alfa de Cronbach, asegurando valores superiores a 0.70 para cada dimensión del MBI, lo que respalda la fiabilidad del instrumento en la muestra seleccionada (Beltran, Moreno, & Salazar, 2016).

Validez de contenido: Se realiza por juicio de expertos en psicología laboral y análisis de datos, quienes evalúan la relevancia, claridad y representatividad de los ítems y variables tecnológicas. Este proceso se apoya en el cálculo del Coeficiente de Validez de Contenido para la integración cuantitativa, y en la integración cualitativa de las observaciones de los jueces (Martínez & Caballero, 2016).

Pruebas piloto: Se aplican pruebas piloto de los instrumentos digitales para identificar posibles problemas de interpretación o funcionamiento, permitiendo ajustes antes de la aplicación definitiva (Carretero Dios-H.Pérez, 2007)

Validación tecnológica: Para los módulos de análisis de sentimientos y reconocimiento facial, se evalúan métricas de precisión, sensibilidad y especificidad, utilizando conjuntos de datos de referencia y validación cruzada (Farley, 2025)

Procedimientos y técnicas de análisis de la información

Los datos cuantitativos serán analizados mediante estadística descriptiva (medias, desviaciones estándar, frecuencias y porcentajes) y análisis correlacional (coeficientes de Pearson y Spearman según la naturaleza de las variables). Para la predicción del riesgo de Burnout, se emplearán modelos de regresión logística y, cuando corresponda, análisis multivariado, utilizando software especializado como SPSS o R (Field, 2018) (Tabachnick, 2019). El análisis del Maslach Burnout Inventory (MBI) seguirá las recomendaciones técnicas internacionales, calculando puntuaciones para cada dimensión (agotamiento emocional, despersonalización y realización personal) y clasificando los perfiles de riesgo según percentiles o puntos de corte validados.

Los datos cualitativos, como comentarios abiertos y entrevistas, serán sometidos a codificación temática siguiendo procedimientos sistemáticos de análisis de contenido. Se utilizará triangulación de fuentes y de investigadores para enriquecer la interpretación y aumentar la validez de los hallazgos (Patton, 2015) (Flick, 2018). La integración de los

resultados cuantitativos y cualitativos permitirá un análisis mixto, facilitando la comprensión holística del fenómeno y la validación cruzada de los resultados (Aguayo Estremera, 2018).

Durante todo el proceso, se implementarán controles de calidad de datos, como la revisión de inconsistencias y la gestión de valores atípicos, y se documentarán los procedimientos para garantizar la replicabilidad y la transparencia. Se respetarán los principios éticos de confidencialidad y consentimiento informado en todas las fases del análisis (Polit, 2017)

Trabajo de Campo

El presente capítulo documenta en detalle el trabajo de campo realizado para el desarrollo de la solución propuesta. Su propósito no es únicamente describir la aplicación de un cuestionario, sino reconstruir la trayectoria metodológica completa que permita pasar de una muestra real recolectada en campo a un prototipo funcional capaz de emitir inferencias y alertas tempranas. En este sentido, el capítulo integra cuatro planos de análisis:

1. El plano psicométrico del instrumento MBI
2. El plano estadístico del tratamiento cuantitativo
3. El plano predictivo de los modelos de aprendizaje automático
4. El plano tecnológico asociado a la implementación en Python, Streamlit y MongoDB.

La organización del capítulo responde a la lógica real del proyecto indicada en el capítulo de la metodología. Primero se describe la labor de investigación realizada y la forma en que se recolectó la información mediante el cuestionario Maslach Burnout Inventory (MBI). Enseguida se expone el proceso de depuración, construcción de variables y definición del dataset semilla. Posteriormente se justifica la necesidad de ampliar el escenario experimental mediante simulación Monte Carlo y se presenta el análisis del conjunto de 5.000 registros en el software estadístico IBM SPSS Statistics (Statistical Package for the Social Sciences). Para finalizar, se explica la transición desde un enfoque monomodal basado en cuestionario hacia un enfoque multimodal que incorpora análisis de sentimiento, análisis de emociones faciales, persistencia (Registro de datos en una base) en MongoDB e interfaz operativa en Streamlit.

Descripción de la labor de investigación realizada


La investigación se desarrolló bajo un enfoque cuantitativo aplicado con orientación tecnológica. El trabajo de campo no se limitó al levantamiento de datos, sino que involucró la construcción progresiva de una evidencia empírica útil para medir, modelar, comparar e implementar una solución orientada a la detección temprana del síndrome de burnout. En coherencia con la pregunta de investigación y con el objetivo general del estudio, el capítulo se diseñó como una ruta de trazabilidad que vincula recolección de datos, modelado predictivo e implementación operativa.

Desde el punto de vista metodológico, el proceso puede entenderse como una secuencia de fases articuladas. La primera fase corresponde a la aplicación del instrumento MBI a una muestra inicial de aproximadamente 110 participantes. La segunda comprende la consolidación del dataset semilla, la depuración de respuestas, la codificación de ítems y la construcción de variables analíticas como $EE_{\{total\}}$, $DP_{\{total\}}$, $RP_{\{total\}}$ y la etiqueta binaria de riesgo. La tercera fase consiste en ampliar el escenario experimental a través de un procedimiento de simulación Monte Carlo, con el fin de obtener un conjunto de datos más estable y más exigente para la evaluación. La cuarta fase se centra en el contraste entre el análisis estadístico tradicional en SPSS, los modelos de machine learning y el desarrollo de una aplicación funcional en entorno local.

Esta forma de organizar la investigación permite que cada resultado obtenido tenga un respaldo metodológico claro. Por un lado, el instrumento MBI aporta la base psicométrica para medir el fenómeno. Por otro, las técnicas estadísticas permiten evaluar consistencia, distribución, asociación y capacidad explicativa de las dimensiones del burnout. Adicionalmente, los modelos predictivos y el prototipo funcional hacen posible transformar el análisis en una propuesta aplicada, interpretable y potencialmente utilizable en procesos de monitoreo preventivo.

Figura 1

Diagrama general del trabajo de campo, desde la recolección MBI hasta la implementación del prototipo multimodal.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Recolección de datos e instrumentos utilizados

La recolección de datos se desarrolló de forma estructurada y coherente con el enfoque cuantitativo adoptado. La fuente primaria estuvo compuesta por una muestra inicial de aproximadamente 110 participantes a quienes se aplicó el Maslach Burnout Inventory (MBI). Este instrumento constituyó la base empírica de toda la investigación, ya que a partir de sus respuestas se construyeron las primeras pruebas predictivas y, posteriormente, el dataset semilla utilizado para la ampliación Monte Carlo.

Instrumento principal: Maslach Burnout Inventory (MBI)

El MBI es uno de los instrumentos más utilizados para la evaluación del síndrome de burnout. En esta investigación se empleó como mecanismo principal de medición debido a que permite capturar tres dimensiones complementarias del fenómeno: agotamiento emocional, despersonalización y realización personal. Estas dimensiones fueron preservadas durante todo el proceso analítico, lo que otorgó trazabilidad entre la etapa de levantamiento, el modelado supervisado y la explicación de las predicciones realizadas por el software.

El cuestionario aplicado estuvo compuesto por 22 ítems medidos en escala tipo Likert de siete categorías, codificadas de 0 a 6, donde 0 representa la ausencia o mínima frecuencia de la experiencia reportada y 6 representa la máxima frecuencia. Para fines computacionales, los ítems se organizaron como i_1 a i_{22} . Esta codificación permitió trabajar con una estructura uniforme tanto en SPSS como en Python.

$$EE_{\{total\}} = i_1 + i_2 + i_3 + i_6 + i_8 + i_{13} + i_{14} + i_{16} + i_{20}$$

$$DP_{\{total\}} = i_5 + i_{10} + i_{11} + i_{15} + i_{22}$$

$$RP_{\{total\}} = i_4 + i_7 + i_9 + i_{12} + i_{17} + i_{18} + i_{19} + i_{21}$$

La interpretación del instrumento siguió la lógica clásica del MBI: puntajes altos en agotamiento emocional y despersonalización se asocian con mayor presencia del síndrome, mientras que puntajes bajos en realización personal indican mayor afectación. En consecuencia, el instrumento no se trató solamente como un conjunto de preguntas, sino como una estructura analítica que permite caracterizar perfiles de riesgo y construir una variable objetivo apta para aprendizaje supervisado.

A partir de los puntos de corte definidos en la investigación, se generó una etiqueta dicotómica denominada Burnout_alto. Dicha etiqueta sintetiza operativamente el criterio de riesgo y permitió llevar el fenómeno desde una lectura psicométrica descriptiva a una formulación predictiva binaria. Esta transformación fue esencial, porque hizo posible comparar el comportamiento del instrumento bajo el enfoque tradicional y bajo algoritmos de clasificación.

Tabla 2

Correspondencia entre los 22 ítems del MBI, la dimensión a la que pertenecen y la escala de respuesta utilizada.

Ítem	Indicador resumido del ítem	Dimensión	Escala de respuesta
i1	Cansancio emocional por el trabajo	Agotamiento emocional (EE)	0–6
i2	Sentirse agotado al terminar la jornada	Agotamiento emocional (EE)	0–6
i3	Fatiga al iniciar una nueva jornada	Agotamiento emocional (EE)	0–6
i4	Comprensión positiva del efecto del trabajo en otras personas	Realización personal (RP)	0–6
i5	Trato impersonal hacia personas atendidas	Despersonalización (DP)	0–6
i6	Sentirse desgastado por trabajar con personas	Agotamiento emocional (EE)	0–6
i7	Capacidad para tratar eficazmente los problemas de otros	Realización personal (RP)	0–6

Ítem	Indicador resumido del ítem	Dimensión	Escala de respuesta
i8	Sensación de estar “quemado” por el trabajo	Agotamiento emocional (EE)	0–6
i9	Influencia positiva del trabajo sobre otras personas	Realización personal (RP)	0–6
i10	Endurecimiento emocional por el trabajo	Despersonalización (DP)	0–6
i11	Preocupación por volverse insensible con las personas	Despersonalización (DP)	0–6
i12	Sentirse con mucha energía en el trabajo	Realización personal (RP)	0–6
i13	Frustración relacionada con el trabajo	Agotamiento emocional (EE)	0–6
i14	Percepción de estar trabajando en exceso	Agotamiento emocional (EE)	0–6
i15	Indiferencia sobre lo que les ocurra a otras personas	Despersonalización (DP)	0–6
i16	Estrés por trabajar directamente con personas	Agotamiento emocional (EE)	0–6
i17	Facilidad para crear un clima relajado con otras personas	Realización personal (RP)	0–6
i18	Sentimiento de logro al trabajar con otras personas	Realización personal (RP)	0–6
i19	Haber conseguido cosas valiosas en el trabajo	Realización personal (RP)	0–6
i20	Sentirse al límite de las posibilidades emocionales	Agotamiento emocional (EE)	0–6
i21	Manejo adecuado de problemas emocionales en el trabajo	Realización personal (RP)	0–6
i22	Culpar a otras personas por problemas del trabajo	Despersonalización (DP)	0–6

Nota. La escala de respuesta utilizada en los 22 ítems fue de tipo Likert de siete categorías: 0 = Nunca; 1 = Pocas veces al año o menos; 2 = Una vez al mes o menos; 3 = Unas pocas veces al mes; 4 = Una vez a la semana; 5 = Pocas veces a la semana; 6 = Todos los días. Los enunciados de la segunda columna se presentan de forma resumida para fines descriptivos; el instrumento completo corresponde al Maslach Burnout Inventory (MBI).

Tabla 3

Rangos de interpretación del MBI para EE, DP y RP, indicando niveles bajo, medio y alto.

Dimensión	Interpretación del puntaje	Nivel bajo	Nivel medio	Nivel alto
Agotamiento emocional (EE)	Directa: mayor puntaje = mayor burnout	0–18	19–26	27–54
Despersonalización (DP)	Directa: mayor puntaje = mayor burnout	0–5	6–9	10–30
Realización personal (RP)	Inversa: menor puntaje = mayor burnout	40–56	34–39	0–33

Nota. En las dimensiones de agotamiento emocional (EE) y despersonalización (DP), los puntajes más altos indican mayor presencia del síndrome de burnout. En la dimensión de realización personal (RP), la interpretación es inversa: los puntajes más bajos se asocian con mayor afectación. Estos rangos se utilizaron como criterio de referencia para la caracterización inicial de los participantes y para la construcción de la variable objetivo del estudio.

Instrumentos complementarios del enfoque multimodal


Aunque el MBI fue la base principal del estudio, el proyecto se diseñó con vocación multimodal. Por ello, se incorporaron instrumentos y herramientas complementarias orientadas al procesamiento de información no estructurada. En particular, se incluyó un componente de análisis de sentimiento sobre texto, un componente de análisis emocional a partir de imágenes y un conjunto de herramientas tecnológicas para la administración del flujo de datos y del software.

Para el análisis de texto se utilizó la librería PySentimiento, especializada en tareas de procesamiento de lenguaje natural para idioma español. Esta herramienta permitió estimar probabilidades asociadas a clases de sentimiento y derivar un conjunto de variables numéricas utilizables por un modelo de clasificación. Para la modalidad visual se recurrió a DeepFace y OpenCV, con el fin de estimar emociones faciales a partir de imágenes cargadas por el usuario. Estas modalidades no se utilizaron como diagnóstico independiente, sino como evidencia complementaria integrada al componente base MBI.

El procesamiento estadístico tradicional se realizó en IBM SPSS Statistics, mientras que la fase de modelado e implementación se desarrolló en Python. El prototipo final se construyó en Streamlit y la persistencia de resultados se resolvió con MongoDB. Esta combinación de herramientas permitió mantener continuidad entre la fase analítica y la fase aplicada del proyecto.

Figura 2

Mapa de instrumentos y herramientas utilizadas, diferenciando MBI, SPSS, Python, PySentimiento, DeepFace, Streamlit y MongoDB



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Procesamiento y preparación de los datos

Una vez recolectadas las respuestas, se realizó la fase de preparación de datos. Esta etapa fue crítica, porque constituyó el puente entre la evidencia original y las fases posteriores de análisis. El procesamiento incluyó revisión de integridad, homogeneización de nombres de columnas, verificación de rangos permitidos, control de valores faltantes y cálculo de variables agregadas. Desde una perspectiva metodológica, esta fase aseguró que el instrumento fuera consumible tanto por herramientas estadísticas como por scripts de entrenamiento.

Consolidación del dataset semilla

La base de datos semilla se construyó a partir del archivo consolidado de encuestas. En esta consolidación se buscó garantizar que cada registro representara un participante con sus 22 respuestas organizadas de manera consistente. La homogeneidad en la codificación permitió mantener intacta la lógica de las subescalas del MBI. Además, se verificó que los ítems permanecieran dentro del rango de 0 a 6, de acuerdo con la estructura Likert definida para el estudio.

Construcción de variables analíticas

Sobre la base semilla se calcularon los subtotales de agotamiento emocional, despersonalización y realización personal. También se definió la variable objetivo Burnout_alto como etiqueta binaria para clasificación. Con ello, el dataset pasó de ser una matriz de respuestas de encuesta a convertirse en un conjunto analítico apropiado para contraste estadístico y aprendizaje supervisado. Esta decisión metodológica fue importante porque permitió medir el mismo fenómeno con lógicas explicativas distintas pero comparables.

La preparación de datos también se diseñó pensando en la fase computacional. El conjunto debía ser interpretable para SPSS y, simultáneamente, compatible con scripts de Python. Por ello, se preservó una estructura explícita de columnas para ítems, subtotales, etiqueta de riesgo y, en etapas posteriores, variables multimodales asociadas a texto e imagen.

Instrumentos y modelos utilizados en el procesamiento

En esta etapa, el procesamiento no se limitó a operaciones mecánicas de limpieza. También se definieron los instrumentos y modelos que participarían en el análisis. En primer lugar, el MBI se mantuvo como instrumento principal y como fuente de variables estructuradas. En segundo lugar, se preparó la integración con IBM SPSS Statistics para análisis descriptivo, confiabilidad, normalidad, correlación y regresión. En tercer lugar, se organizó la información para ser utilizada por modelos de machine learning de enfoque monomodal basados únicamente en el MBI, particularmente Regresión Logística, Random Forest y Support Vector Machine.

La diferencia entre el análisis monomodal y el análisis multimodal radica en la naturaleza de las fuentes de información. El monomodal utiliza exclusivamente los datos estructurados del cuestionario MBI. El multimodal, en cambio, adiciona una fuente textual y una fuente visual, traduciendo ambas a scores numéricos compatibles con el modelo base. Esta distinción es metodológicamente relevante, porque el monomodal evalúa la capacidad del instrumento tradicional de forma aislada, mientras que el multimodal examina el valor agregado de integrar señales heterogéneas en una única inferencia.

En términos operativos, los modelos comparativos aplicados al análisis inicial de la muestra semilla fueron Regresión Logística, Random Forest y SVM, debido a su utilidad como líneas base de clasificación. Sin embargo, en el software implementado se optó por una arquitectura de ensamble basada en modelos probabilísticos interpretables, en la que el componente MBI y el componente de sentimiento se entrenan como modelos separados y sus salidas se combinan junto con un score emocional derivado de la imagen.

Tabla 4

Estructura final del dataset semilla, indicando ítems MBI, subtotales, variable objetivo y variables preparadas para el enfoque multimodal.

Grupo de variables	Variable(s)	Tipo / escala	Descripción funcional	Uso analítico
Identificación	employee_id o id_empleado	Nominal / texto	Código único del participante	Trazabilidad del registro
Ítems del MBI	i1–i22	Ordinal Likert (0–6)	Respuestas individuales al cuestionario MBI	Base del análisis monomodal
Subescala MBI	EE_total	Escala / numérica	Suma de ítems de agotamiento emocional	Variable explicativa
Subescala MBI	DP_total	Escala / numérica	Suma de ítems de despersonalización	Variable explicativa
Subescala MBI	RP_total	Escala / numérica	Suma de ítems de realización personal	Variable explicativa
Variable objetivo	Burnout_alto	Binaria (0/1)	Clasificación operativa de riesgo alto de burnout	Variable dependiente / etiqueta de clase
Texto para NLP	texto_comentario	Texto libre	Comentario breve del participante sobre su estado emocional o laboral	Entrada para análisis de sentimiento
Imagen para emociones	imagen o ruta_imagen	Archivo / referencia	Imagen facial opcional asociada al participante	Entrada para análisis emocional
Variable derivada multimodal	p_sent	Continua [0,1]	Probabilidad o score derivado del análisis de sentimiento	Componente del ensamble multimodal

Grupo de variables	Variable(s)	Tipo / escala	Descripción funcional	Uso analítico
Variable derivada multimodal	p_emo	Continua [0,1]	Score emocional derivado del análisis facial	Componente del ensamble multimodal
Variable derivada monomodal	p_mbi	Continua [0,1]	Probabilidad de burnout estimada por el modelo basado en MBI	Componente base del ensamble
Variable integrada	p_final	Continua [0,1]	Probabilidad final obtenida tras integrar MBI, sentimiento y emoción	Salida del modelo multimodal
Variable categórica final	nivel	Categórica ordinal	Bajo, medio o alto según el valor de la probabilidad final	Interpretación del resultado

Nota. El dataset semilla se construyó inicialmente a partir de las respuestas del cuestionario MBI recolectadas en campo. A partir de este conjunto base se calcularon los subtotales de las dimensiones EE_total, DP_total y RP_total, así como la variable objetivo Burnout_alto. Las variables texto_comentario e imagen o ruta_imagen corresponden a las entradas complementarias previstas para el enfoque multimodal, mientras que p_sent, p_emo, p_mbi y p_final representan variables derivadas del procesamiento computacional y de los modelos predictivos implementados.

Resultados iniciales con la muestra semilla y escenario experimental

El primer hallazgo relevante del trabajo de campo surgió al entrenar modelos de clasificación sobre la muestra original. La evidencia disponible para el análisis MBI mostró que, sobre un conjunto de prueba muy pequeño, Random Forest y SVM alcanzaban métricas perfectas o prácticamente perfectas, mientras que la regresión logística también presentaba un desempeño muy alto. A primera vista, estos resultados podrían interpretarse como una prueba de excelencia del sistema; sin embargo, desde la perspectiva metodológica constituyeron una señal de alerta.

Las métricas ideales en muestras pequeñas suelen asociarse con baja variabilidad, patrones excesivamente nítidos o sobreajuste. En otras palabras, el modelo puede estar aprendiendo con demasiada fidelidad las particularidades de una muestra limitada, sin que ello garantice capacidad real de generalización. Esta interpretación resulta especialmente importante en una tesis aplicada, porque evita confundir desempeño aparente con robustez estadística.

En este caso, la muestra semilla fue suficiente para identificar señal predictiva en las dimensiones del MBI, pero no para afirmar con seguridad que el fenómeno hubiera sido modelado de manera realista. Por ello, el trabajo de campo no presenta las métricas perfectas como resultado concluyente, sino como evidencia de la necesidad de fortalecer el diseño experimental. La respuesta metodológica a este hallazgo fue la ampliación controlada del escenario mediante simulación Monte Carlo.

Métricas de evaluación de los modelos predictivos

Para interpretar adecuadamente los resultados preliminares presentados en la tabla de resultados preliminares de los modelos predictivos, fue necesario precisar la nomenclatura de evaluación empleada en los modelos de clasificación. Las métricas se derivan de la matriz de confusión, la cual contrasta la clase real con la clase predicha por el modelo. En este contexto, los verdaderos positivos (VP) corresponden a los casos con riesgo de burnout que fueron identificados correctamente; los verdaderos negativos (VN), a los casos sin riesgo alto clasificados correctamente; los falsos positivos (FP), a los casos sin riesgo alto clasificados erróneamente como riesgo; y los falsos negativos (FN), a los casos con riesgo que el modelo no logró identificar.

La exactitud o accuracy representa la proporción de clasificaciones correctas del modelo respecto al total de observaciones evaluadas y se expresa mediante la siguiente ecuación:

$$Accuracy, (Exactitud) = \frac{VP + VN}{VP + VN + FP + FN}$$

Aunque esta métrica permite observar el desempeño global del modelo, no debe interpretarse de forma aislada, especialmente cuando interesa la detección temprana de posibles casos de riesgo.

El recall o sensibilidad mide la capacidad del modelo para identificar correctamente los casos reales de riesgo de burnout. Su expresión es:

$$Recall, (Sensibilidad) = \frac{VP}{VP + FN}$$

En esta investigación, el recall resulta especialmente relevante porque un falso negativo implicaría no detectar oportunamente a un trabajador con posible riesgo de burnout.

La precisión o precision indica qué proporción de los casos clasificados como riesgo realmente correspondían a casos de riesgo:

$$Precision, (Precisión) = \frac{VP}{VP + FP}$$

Esta métrica permite valorar la proporción de alertas correctas frente al total de alertas generadas por el modelo.

El F1-score corresponde a la media armónica entre precision y recall, por lo que permite observar un balance entre la detección de casos de riesgo y la reducción de falsas alertas:

$$F1_{score}, (Puntaje F1) = 2 \times \frac{Precisión \times Recall}{Precisión + Recall}$$

Por su parte, la curva ROC (Receiver Operating Characteristic) permite analizar el comportamiento del modelo al variar el umbral de clasificación, relacionando la tasa de verdaderos positivos con la tasa de falsos positivos. El AUC-ROC corresponde al área bajo dicha curva y resume la capacidad del modelo para discriminar entre casos con riesgo y sin riesgo de burnout. Valores más cercanos a 1 indican mayor capacidad discriminativa, mientras que valores cercanos a 0.5 reflejan un comportamiento similar al azar.

Antes de presentar los resultados preliminares de los modelos de clasificación (**Tabla 5**), es importante señalar que las métricas obtenidas en la muestra semilla deben interpretarse con cautela. Aunque indicadores como accuracy, recall, F1-score y AUC-ROC permiten evaluar el desempeño inicial de los modelos, los valores excesivamente altos pueden estar asociados al tamaño reducido de la muestra, a la estructura de los datos o a un posible sobreajuste. Por esta razón, los resultados obtenidos con los 110 registros iniciales no se asumieron como evidencia concluyente de generalización del modelo, sino como una aproximación exploratoria. Esta situación justificó la aplicación posterior de una simulación Monte Carlo con 5.000 registros, con el propósito de ampliar el escenario experimental, observar mayor variabilidad en los datos y contar con una base más estable para el análisis comparativo.

Tabla 5

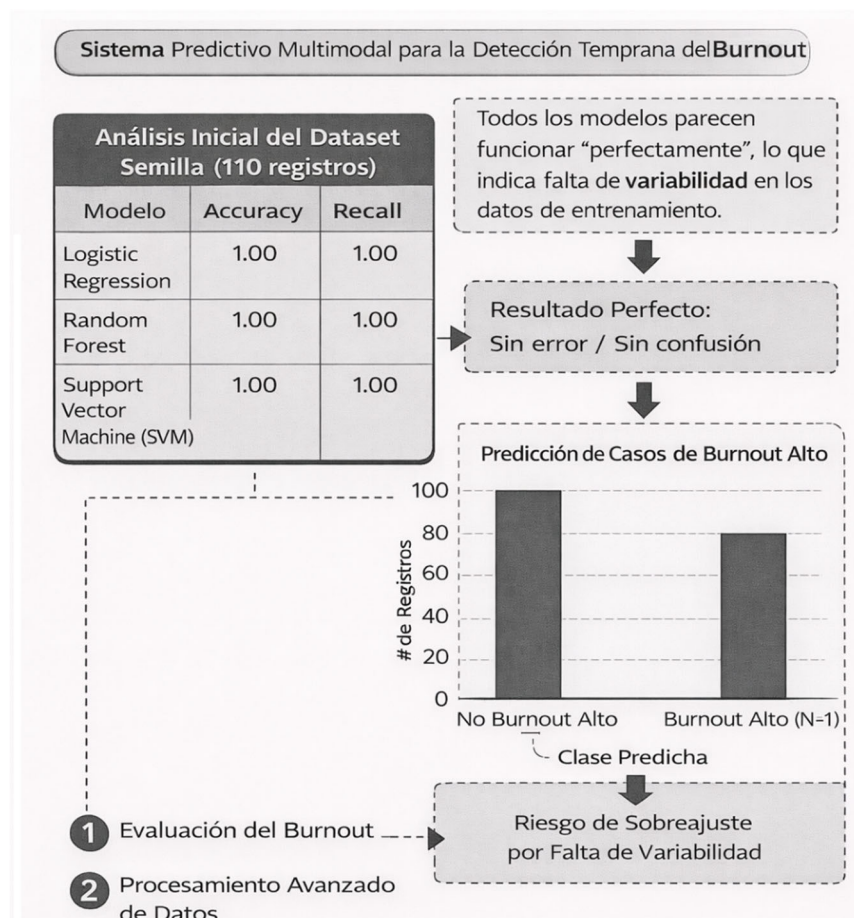
Resultados preliminares de Regresión Logística, Random Forest y SVM sobre la muestra semilla, incluyendo accuracy, recall, F1-score y AUC-ROC.

Modelo	Accuracy	Recall	F1-score	AUC-ROC
Regresión Logística	0.864	1.000	0.919	0.718
Random Forest	1.000	1.000	1.000	1.000
SVM	1.000	1.000	1.000	1.000

Nota. Los resultados preliminares fueron obtenidos sobre la muestra semilla derivada del cuestionario MBI. Se observa un desempeño aparentemente perfecto en los modelos Random Forest y SVM, así como un desempeño muy alto en Regresión Logística. Desde una perspectiva metodológica, estos resultados deben interpretarse con cautela, ya que pueden reflejar baja variabilidad muestral, tamaño reducido del conjunto de prueba o riesgo de sobreajuste, razón por la cual se justificó la ampliación del escenario experimental mediante simulación Monte Carlo.

Figura 3

Captura del análisis inicial del dataset de 110 registros y comentario visual sobre el riesgo de sobreajuste.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Generación del conjunto sintético mediante simulación Monte Carlo

La simulación Monte Carlo se incorporó como estrategia metodológica para ampliar la muestra inicial y construir un escenario de evaluación más estable. Su propósito no fue reemplazar la evidencia real recolectada en campo, sino crear una extensión experimental que preservara la lógica del instrumento y permitiera evaluar el comportamiento de los métodos en un entorno más amplio y heterogéneo.

Justificación metodológica

La razón principal para recurrir a Monte Carlo fue la necesidad de reducir la inestabilidad derivada del tamaño de la muestra semilla y de las particiones pequeñas de entrenamiento y prueba. La ampliación a 5.000 registros ofreció dos ventajas centrales: primero, introdujo mayor dispersión y heterogeneidad en los datos; segundo, permitió someter el fenómeno a pruebas más exigentes sin perder la estructura conceptual del MBI.

Procedimiento seguido

De acuerdo con la estructura del archivo resultante y con la lógica general del proyecto, la construcción del dataset Monte Carlo implicó las siguientes etapas metodológicas:

- i) Consolidación de la muestra semilla como base empírica;
- ii) Identificación de la arquitectura del instrumento y de las relaciones entre sus dimensiones;

- iii) Generación probabilística de nuevos registros respetando el rango Likert de los ítems;
- iv) Recálculo de subtotales $EE_{\{total\}}$, $DP_{\{total\}}$ y $RP_{\{total\}}$; definición o arrastre de la etiqueta Burnout_alto para el nuevo escenario;
- v) Incorporación de variables multimodales complementarias asociadas a texto e imagen.

La fase de simulación, el dataset Monte Carlo evidencia que el procedimiento respetó la arquitectura del instrumento. El archivo final preserva las columnas i1 a i22, las variables agregadas $EE_{\{total\}}$, $DP_{\{total\}}$ y $RP_{\{total\}}$, la etiqueta Burnout_alto y, además, campos asociados al componente textual y emocional, tales como sentiment_text, dominant_emotion, emotion_confidence, valence, arousal y las probabilidades emocionales específicas.


Resultado de la ampliación

El dataset ampliado quedó conformado por 5.000 registros y 43 variables. En él, la distribución de la etiqueta Burnout_alto presentó 2.398 casos en la clase 0 y 2.602 casos en la clase 1, lo cual representa una proporción cercana al equilibrio y facilita el entrenamiento y la comparación entre métodos. El archivo también integró explícitamente la dimensión multimodal del proyecto, al incluir texto de sentimiento y variables de emoción derivadas del procesamiento de imágenes.

Desde la perspectiva de la tesis, el mayor valor de la simulación no radica únicamente en el aumento del tamaño muestral, sino en haber convertido un experimento potencialmente frágil en un escenario metodológicamente robusto. La simulación funcionó como mecanismo de robustecimiento del diseño: si los patrones observados inicialmente correspondían a señal real, debían seguir manifestándose en un conjunto más amplio; si se trataba de un artificio de la muestra pequeña, el rendimiento debía moderarse.

Figura 4

Diagrama del procedimiento de simulación Monte Carlo desde el dataset semilla hasta el dataset de 5.000 registros



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Tabla 6

Comparación entre dataset semilla y dataset Monte Carlo, incluyendo número de casos, variables, medias y dispersión por dimensión.

Indicador	Dataset semilla	Dataset Monte Carlo
Número de casos	100	5000
Variables base	22 ítems MBI + EE_total + DP_total + RP_total + niveles	22 ítems MBI + EE_total + DP_total + RP_total + Burnout_alto + variables multimodales
Dimensión EE_total (media)	31.83	29.65
Dimensión EE_total (desviación estándar)	4.304	12.045
Dimensión EE_total (mínimo–máximo)	20–43	0–54
Dimensión DP_total (media)	17.83	15.93
Dimensión DP_total (desviación estándar)	3.782	7.523
Dimensión DP_total (mínimo–máximo)	8–26	0–30
Dimensión RP_total (media)	27.89	27.47
Dimensión RP_total (desviación estándar)	4.207	10.347
Dimensión RP_total (mínimo–máximo)	17–37	0–49
Nivel de dispersión observado	Reducido / concentrado	Mayor / más heterogéneo
Utilidad analítica principal	Pruebas preliminares y detección del problema de sobreajuste	Análisis estadístico robusto, contrastación y entrenamiento ampliado

Nota. El dataset semilla corresponde al conjunto consolidado de respuestas reales del cuestionario MBI utilizado como base empírica inicial del estudio. En el texto del capítulo se reporta una muestra de aproximadamente 110 participantes, mientras que el archivo CSV consolidado disponible para el cálculo descriptivo contiene 100 registros válidos; por ello, se recomienda verificar cuál de las dos cifras desea conservar de forma definitiva en la versión final de la tesis. Para el dataset Monte Carlo, los valores de media y desviación estándar de EE_total, DP_total y RP_total coinciden con los estadísticos reportados en el análisis efectuado en IBM SPSS Statistics sobre el archivo de 5.000 registros.

Análisis cuantitativo tradicional en IBM SPSS Statistics

Una vez consolidado el conjunto Monte Carlo, se realizó su análisis en IBM SPSS Statistics. Esta fase tuvo una importancia particular porque permitió contrastar la aproximación puramente predictiva con una lectura estadística tradicional del fenómeno. El objetivo fue verificar consistencia interna, describir el comportamiento de las variables y evaluar la relación entre las dimensiones del MBI y la etiqueta de riesgo.

Procedimiento general en SPSS

El procedimiento seguido se apoyó en la secuencia metodológica descrita en el módulo de soporte estadístico utilizado durante la investigación. Primero, el archivo de datos fue preparado en formato tabular y convertido a un archivo .sav para facilitar su lectura en SPSS. Luego se ajustó el tipo de variable según su naturaleza, distinguiendo entre variables de escala, ordinales y nominales. En el caso de esta tesis, los ítems Likert fueron tratados como variables ordinales en su lectura original, mientras que los subtotales y algunas variables agregadas fueron interpretados como variables de escala para fines descriptivos y de regresión.

Posteriormente se ejecutaron tablas de frecuencias y estadísticos descriptivos para revisar comportamiento general, rangos, medias y desviaciones estándar. Enseguida se evaluó la consistencia interna del instrumento mediante el alfa de Cronbach, siguiendo el criterio usual según el cual valores superiores a 0,70 son aceptables para investigación social. Después se revisó la forma de la distribución mediante pruebas de normalidad y, con base en esa evaluación y en la naturaleza de las variables, se optó por el coeficiente de correlación de Spearman para estudiar asociación entre dimensiones y etiqueta de riesgo. Finalmente, se estimó un modelo de

regresión con el fin de establecer el peso explicativo de las dimensiones del burnout sobre la variable objetivo.

Resultados psicométricos y descriptivos

El análisis del conjunto Monte Carlo mostró que el instrumento conservó una estructura interna coherente. Los coeficientes alfa de Cronbach obtenidos fueron 0,811 para agotamiento emocional, 0,706 para despersonalización y 0,787 para realización personal. Estos valores indican una consistencia interna aceptable a buena para las tres subescalas y respaldan la validez operativa del dataset ampliado como representación estructurada del MBI.

Los estadísticos descriptivos de las tres dimensiones también fueron coherentes con la amplitud esperada del fenómeno. Las medias fueron 29,65 para $EE_{\{total\}}$, 15,93 para $DP_{\{total\}}$ y 27,47 para $RP_{\{total\}}$, con desviaciones estándar de 12,045; 7,523 y 10,347, respectivamente. La dispersión observada confirma que el escenario Monte Carlo no reproduce una nube excesivamente compacta, sino un conjunto de perfiles heterogéneos, condición deseable después de haber detectado resultados idealizados en la muestra semilla.

Asociación entre variables y modelo de regresión

Las correlaciones de Spearman entre las dimensiones y la etiqueta Burnout_alto mostraron una estructura coherente con la teoría del burnout. El agotamiento emocional se correlacionó positivamente con la etiqueta de riesgo ($p = 0,736$), la despersonalización también mostró una asociación positiva relevante ($p = 0,509$) y la realización personal presentó una relación negativa ($p = -0,149$). En términos conceptuales, estos resultados significan que a mayor

agotamiento emocional y a mayor despersonalización, mayor es la probabilidad de riesgo alto, mientras que una mayor realización personal tiende a relacionarse con menor riesgo.

El modelo de regresión ejecutado en SPSS presentó un coeficiente R de 0,773 y un R^2 de 0,597, con significancia global $p < 0,001$. A nivel de coeficientes, $EE_{\{total\}}$, tuvo el mayor peso explicativo ($B = 0,025$; $\beta = 0,614$; $p < 0,001$), seguido por $DP_{\{total\}}$ ($B = 0,020$; $\beta = 0,305$; $p < 0,001$). $RP_{\{total\}}$, no resultó significativo en ese modelo específico ($p = 0,368$), lo que no implica que la dimensión carezca de valor conceptual, sino que su capacidad incremental de explicación se reduce cuando el agotamiento emocional y la despersonalización ya están presentes en el modelo.


Tabla 7

Indicadores psicométricos y descriptivos del dataset Monte Carlo, incluyendo alfa de Cronbach, medias, desviaciones estándar, mínimos y máximos.

Indicador	EE	DP	RP
Alfa de Cronbach	0.811	0.706	0.787
Media	29.65	15.93	27.47
Desviación estándar	12.045	7.523	10.347
Mínimo	0	0	0
Máximo	54	30	49

Nota. EE = agotamiento emocional; DP = despersonalización; RP = realización personal. Los coeficientes alfa de Cronbach indican una consistencia interna aceptable a buena en las tres subescalas del instrumento, mientras que las medias, desviaciones estándar y rangos muestran que el dataset Monte Carlo presenta una dispersión suficiente para reflejar perfiles heterogéneos de burnout. El tamaño del conjunto analizado fue de $n = 5.000$ registros.

Figura 5
Scores de EE_total, DP_total y RP_total del dataset Monte Carlo.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Tabla 8
Matriz de correlaciones de Spearman entre las dimensiones del MBI y la variable Burnout_alto en el dataset Monte Carlo

Variable 1	Variable 2	Coefficiente de Spearman (ρ)	Significancia	Interpretación
EE_total	Burnout_alto	0.736	p < 0.001	Asociación positiva alta
DP_total	Burnout_alto	0.509	p < 0.001	Asociación positiva moderada
RP_total	Burnout_alto	-0.149	No reportada / baja	Asociación negativa baja

Nota. EE = agotamiento emocional; DP = despersonalización; RP = realización personal. Las correlaciones de Spearman muestran asociaciones coherentes con la teoría del burnout: a mayor agotamiento emocional y despersonalización, mayor probabilidad de clasificación en la categoría Burnout_alto; en contraste, la realización personal presenta una asociación negativa de baja magnitud. Estos resultados respaldan la validez conceptual del comportamiento del dataset Monte Carlo y su utilidad para el análisis cuantitativo posterior.

Tabla 9


Resumen del modelo de regresión en SPSS para el dataset Monte Carlo.

Componente	Indicador / variable	Valor	Significancia	Interpretación
Resumen del modelo	R	0.773	$p < 0.001$	Correlación múltiple del modelo
Resumen del modelo	R^2	0.597	$p < 0.001$	Proporción de varianza explicada
ANOVA del modelo	F	2469.113	$p < 0.001$	Modelo globalmente significativo
Coefficientes	EE_total: B = 0.025; $\beta = 0.614$	0.025 / 0.614	$p < 0.001$	Predictor positivo principal
Coefficientes	DP_total: B = 0.020; $\beta = 0.305$	0.020 / 0.305	$p < 0.001$	Predictor positivo secundario
Coefficientes	RP_total: B $\approx$ 0.000; $\beta = 0.008$	≈ 0.000 / 0.008	$p = 0.368$	No significativo en el modelo

Nota. El modelo de regresión ejecutado en SPSS indica que las dimensiones agotamiento emocional y despersonalización aportan capacidad explicativa significativa sobre la variable Burnout_alto, siendo EE_{total} , el predictor con mayor peso relativo. Aunque la dimensión realización personal conserva relevancia teórica dentro del constructo burnout, en este modelo específico no mostró significancia estadística al analizarse simultáneamente con las otras dimensiones.

Figura 6

Esquema del procedimiento en SPSS, desde importación .sav hasta correlación y regresión.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Modelado predictivo monomodal y contraste con machine learning

El enfoque monomodal del proyecto se basó exclusivamente en la información estructurada del MBI. En esta fase se buscó determinar hasta qué punto las respuestas del cuestionario, por sí solas, eran suficientes para predecir la categoría de riesgo. Para ello se compararon modelos de Regresión Logística, Random Forest y Support Vector Machine. Esta comparación permitió establecer una línea base predictiva antes de incorporar las modalidades de texto e imagen.

Los resultados iniciales sobre la muestra semilla mostraron un comportamiento llamativo: Random Forest y SVM alcanzaron métricas perfectas en el conjunto de prueba pequeño, mientras que la Regresión Logística presentó un rendimiento también elevado, aunque menos extremo. Esta situación reforzó la lectura de que el MBI contenía señal predictiva real, pero al mismo tiempo evidenció la fragilidad de trabajar con pocas observaciones. Por esta razón, el verdadero valor de los modelos monomodales no fue entregar una respuesta definitiva, sino servir como línea base y punto de comparación frente al escenario ampliado.

En la arquitectura del software implementado, la lógica monomodal se preservó en el componente MBI base. El script de entrenamiento del ensamble construye un modelo probabilístico específico para el cuestionario, utilizando como entrada los ítems $i1$ a $i22$ y, cuando están disponibles, los subtotales $EE_{\{total\}}$, $DP_{\{total\}}$ y $RP_{\{total\}}$. Esta decisión técnica fue conveniente porque permite obtener una probabilidad base interpretable, a partir de la cual las modalidades adicionales ajustan el resultado sin desplazar el papel central del instrumento.

Tabla 10


Comparación entre Regresión Logística, Random Forest y SVM en el enfoque monomodal.

Modelo	Tipo de algoritmo	Variables de entrada	Accuracy	Recall	F1-score	AUC-ROC	Interpretación
Regresión Logística	Lineal probabilístico	EE_total, DP_total, RP_total	0.864	1.000	0.919	0.718	Desempeño alto, pero inferior a Random Forest y SVM en la muestra semilla
Random Forest	Ensamble basado en árboles	EE_total, DP_total, RP_total	1.000	1.000	1.000	1.000	Desempeño perfecto; posible efecto de baja variabilidad u overfitting
SVM	Máquina de soporte vectorial	EE_total, DP_total, RP_total	1.000	1.000	1.000	1.000	Desempeño perfecto; requiere interpretación cautelosa por posible sobreajuste

Nota. El enfoque monomodal utiliza exclusivamente las variables derivadas del cuestionario Maslach Burnout Inventory (MBI), particularmente los subtotales EE_{total} , DP_{total} y RP_{total} , como predictores de la variable objetivo Burnout_alto. Los resultados presentados corresponden a la fase preliminar de experimentación sobre la muestra semilla. Aunque Random Forest y SVM alcanzaron métricas perfectas, estos hallazgos deben interpretarse con cautela, ya que pueden reflejar baja heterogeneidad muestral, tamaño reducido del conjunto de prueba o riesgo de sobreajuste. Por ello, posteriormente se amplió el escenario experimental mediante simulación Monte Carlo para contrastar el comportamiento de los modelos en condiciones más robustas.

Figura 7

Diagrama comparativo entre el método tradicional, el enfoque monomodal con machine learning y el enfoque multimodal.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Construcción del enfoque multimodal

La transición hacia un enfoque multimodal respondió a una idea central del proyecto: el burnout no siempre se expresa de manera completa en una sola fuente de información. Una persona puede reportar agotamiento elevado en el cuestionario, utilizar un lenguaje emocionalmente moderado en su comentario escrito y, al mismo tiempo, presentar una expresión facial neutra o controlada. Por ello, la solución se diseñó para integrar señales heterogéneas y producir una inferencia conjunta más rica y más útil que la obtenida con una sola modalidad.

Modalidad textual: análisis de sentimiento

El componente textual se implementó con PySentimiento. A partir del comentario escrito por el usuario, el analizador produce probabilidades para distintas clases de sentimiento. Sobre esta base se generaron cuatro características numéricas:

$sent_{\{pos\}}$, $sent_{\{neu\}}$, $sent_{\{neg\}}$ y $sent_{\{score\}}$,

donde este último se calcula como la diferencia entre la probabilidad positiva y la probabilidad negativa.

$$sent_{\{score\}} = sent_{\{pos\}} - sent_{\{neg\}}$$

Estas variables se utilizan como entrada de un modelo de clasificación independiente para la modalidad textual. Si el usuario no aporta texto o el sistema no puede obtener una clasificación confiable, la modalidad se trata como neutral. En términos operativos, ello equivale a evitar que la ausencia de texto introduzca un sesgo artificial en la inferencia final.

Modalidad visual: análisis de emociones faciales con DeepFace

La modalidad visual se implementó mediante DeepFace y OpenCV. El usuario puede cargar una imagen en formato JPG o PNG, tras lo cual el sistema intenta detectar un rostro y estimar la distribución de emociones básicas. Entre las variables observadas en el archivo multimodal se encuentran `dominant_emotion`, `emotion_confidence`, `valence`, `arousal`, `emo_risk`, `emo_weight` y los porcentajes asociados a emociones como `angry`, `fear`, `sad`, `happy`, `surprise` y `neutral`.

En el código de la aplicación, la distribución emocional se transforma a una probabilidad de riesgo mediante una heurística explícita: las emociones negativas como ira, miedo, tristeza y disgusto aumentan el riesgo; la alegría y, en menor medida, la neutralidad lo reducen; la sorpresa se considera una señal de efecto leve. Esto produce un score $P_{\{emo\}}$ dentro del intervalo $[0,1]$, centrado en 0,5 cuando la señal emocional es neutra o insuficiente.

Negativo emocional:

$$N_{\{emo\}} = emo_{\{angry\}} + emo_{\{fear\}} + emo_{\{sad\}} + emo_{\{disgust\}}$$

Positivo emocional:

$$P_{\{emo\}} = emo_{\{happy\}} + 0.5 \cdot emo_{\{neutral\}}$$

Valor bruto:

$$R_{\{emo\}} = (N_{\{emo\}} + 0.25 \cdot emo_{\{surprise\}}) - P_{\{emo\}}$$

Probabilidad emocional final:

$$p_{\{emo\}} = \max\left(0, \min\left(1, 0.5 + \max\left(-0.35, \min\left(0.35, \frac{0.35 \cdot R_{\{emo\}}}{100}\right)\right)\right)\right)$$

Si el usuario no carga imagen, si el entorno no tiene disponible la pila DeepFace/OpenCV, o si no se detecta un rostro con suficiente claridad, el sistema no fuerza una salida artificial. En su lugar, adopta una contribución neutral para la modalidad emocional, lo cual es consistente con el criterio de no penalizar la ausencia de información no estructurada.

Integración de modalidades: fórmula de relación y pesos

La integración multimodal se implementó con dos estrategias posibles: promedio ponderado y delta acotado. La primera combina las probabilidades de cada modalidad de acuerdo con pesos explícitos. La segunda, que aparece como estrategia por defecto en la aplicación, parte de la probabilidad base del MBI y la ajusta de manera controlada con la evidencia de sentimiento y emoción. Esta última opción es metodológicamente valiosa porque protege la centralidad del instrumento validado y, al mismo tiempo, permite que las modalidades complementarias añadan contexto sin dominar por completo la decisión.

Ensamble por promedio ponderado

$$p_{\{final\}} = \frac{w_{\{MBI\}}p_{\{MBI\}} + w_{\{sent\}}p_{\{sent\}} + w_{\{emo\}}p_{\{emo\}}}{w_{\{MBI\}} + w_{\{sent\}} + w_{\{emo\}}}$$

Donde $p_{\{final\}}$ pertenece al intervalo $[0,1]$

La estrategia de ensamble por promedio ponderado consiste en integrar las probabilidades generadas por las distintas modalidades del sistema (cuestionario MBI, análisis de sentimiento y análisis emocional facial) mediante una combinación lineal normalizada por la suma de los pesos asignados a cada componente. En esta formulación, $p_{\{MBI\}}$ actúa como la probabilidad base derivada del instrumento psicométrico, mientras que $p_{\{sent\}}$ y $p_{\{emo\}}$ representan las contribuciones complementarias provenientes del texto y de la imagen, respectivamente. Los parámetros $w_{\{MBI\}}$, $w_{\{sent\}}$ y $w_{\{emo\}}$ controlan la importancia relativa de cada modalidad dentro de la estimación final.

Desde el punto de vista metodológico, esta estrategia permite un esquema de integración flexible y fácilmente interpretable, ya que la influencia de cada fuente de información puede ajustarse explícitamente según su relevancia o confiabilidad. En consecuencia, el promedio ponderado resulta útil cuando se desea combinar varias señales de forma equilibrada, manteniendo una relación proporcional entre sus aportes. No obstante, su principal limitación es que, si los pesos no se calibran adecuadamente, una modalidad secundaria podría ejercer una influencia excesiva sobre la probabilidad final. Por esta razón, en el desarrollo del prototipo esta estrategia puede entenderse como una alternativa de integración lineal, útil para fines comparativos y de experimentación.

Ensamble con delta acotado

$$p_{\{final\}} = p_{\{MBI\}} + \delta_s + \delta_e$$

Ajuste del sentimiento

$$\delta_s = \max\left(-\Delta_s, \min(\Delta_s, p_{\{sent\}} - 0.5)\right)$$

Ajuste de la emoción

$$\delta_e = \max\left(-\Delta_e, \min(\Delta_e, p_{\{emo\}} - 0.5)\right)$$

Donde $p_{\{final\}}$ pertenece al intervalo $[0,1]$

$$p_{\{final\}} = p_{\{MBI\}} + \max\left(-\Delta_s, \min(\Delta_s, p_{\{sent\}} - 0.5)\right) \\ + \max\left(-\Delta_e, \min(\Delta_e, p_{\{emo\}} - 0.5)\right)$$

$$0 \leq p_{\{final\}} \leq 1$$

La estrategia de ensamble con delta acotado parte de la probabilidad base $p_{\{MBI\}}$ y la ajusta mediante dos términos adicionales, δ_s y δ_e , que representan la contribución del análisis de sentimiento y del análisis emocional facial, respectivamente. A diferencia del promedio ponderado, este enfoque no combina todas las modalidades en una media global, sino que conserva al MBI como eje principal de la inferencia y permite que las demás modalidades solo modifiquen el resultado dentro de límites previamente definidos. En términos operativos, cada ajuste se calcula a partir de la diferencia entre la probabilidad complementaria y el valor neutro 0.5, y posteriormente se restringe al intervalo determinado por Δ_s y Δ_e

Esta formulación ofrece una ventaja importante en contextos aplicados: reduce el riesgo de que una modalidad secundaria, como el texto o la imagen, domine la decisión final del modelo. En otras palabras, aunque el sentimiento y la emoción aportan información adicional relevante, su efecto se mantiene controlado y acotado, lo que favorece la estabilidad, interpretabilidad y robustez del sistema. Por ello, el ensamble con delta acotado resulta especialmente apropiado para la presente investigación, ya que preserva la centralidad del instrumento MBI como base psicométrica del diagnóstico y, al mismo tiempo, incorpora señales multimodales de manera prudente y metodológicamente consistente.

Las ecuaciones presentadas para el ensamble multimodal corresponden a la lógica de integración implementada en el prototipo desarrollado en esta investigación. No constituyen una formulación teórica universal del burnout, sino una formalización operativa diseñada para combinar la probabilidad base del MBI con señales complementarias de sentimiento y emoción facial, manteniendo interpretabilidad y control sobre la influencia de cada modalidad. La estrategia de promedio ponderado representa una combinación lineal de fuentes, mientras que la estrategia de delta acotado introduce ajustes limitados alrededor de la probabilidad base, evitando que una modalidad secundaria desplace de manera excesiva la inferencia principal y en conjunto, ambas estrategias muestran dos formas complementarias de integrar información multimodal: el promedio ponderado como mecanismo de combinación lineal flexible, y el delta acotado como esquema de ajuste controlado alrededor de la probabilidad base del MBI. En esta investigación, la segunda estrategia adquiere especial relevancia por su mayor interpretabilidad y por el control explícito que ejerce sobre la influencia de las modalidades complementarias.

En la interfaz observada, los parámetros de configuración por defecto asignan a sentimiento y emoción un impacto máximo de 0,15 cuando se emplea la estrategia de delta acotado. Esto significa que cada modalidad secundaria puede desplazar la probabilidad base del MBI hasta un máximo de $\pm 0,15$, pero no más. Conceptualmente, esta regla evita inferencias extremas originadas en una sola fuente complementaria y favorece la interpretabilidad del resultado final.

La diferencia entre el enfoque monomodal y el multimodal, por tanto, no se reduce a añadir más variables. El enfoque multimodal agrega una lógica de reconciliación entre señales que pueden ser convergentes o disonantes. En un contexto de burnout, esa disonancia es particularmente importante, porque una persona puede responder el cuestionario de una forma, expresarse por escrito de otra y no manifestar el mismo estado en su expresión facial. El software no elimina esa complejidad; la hace visible y operativamente utilizable.

Tabla 11

Definición de p_MBI , p_sent , p_emo , pesos del ensamble y estrategia de integración.


Elemento	Definición funcional	Rango o valor de referencia	Papel dentro del modelo multimodal	Observación metodológica
p_MBI	Probabilidad base estimada por el modelo predictivo construido a partir del cuestionario MBI	[0,1]	Componente principal del ensamble	Representa la señal psicométrica central del sistema
p_sent	Probabilidad o score derivado del análisis de sentimiento del texto mediante PySentimiento	[0,1]	Ajuste complementario del resultado base	Si no hay texto o no puede analizarse, se asigna valor neutro 0.5
p_emo	Probabilidad o score emocional derivado del análisis facial mediante DeepFace	[0,1]	Ajuste complementario del resultado base	Si no hay imagen o no se detecta rostro confiable, se asigna valor neutro 0.5
cap_sent	Impacto máximo permitido para la modalidad de sentimiento	0.15	Limita cuánto puede modificar a p_MBI	Evita que el texto domine la inferencia final

Elemento	Definición funcional	Rango o valor de referencia	Papel dentro del modelo multimodal	Observación metodológica
cap_emo	Impacto máximo permitido para la modalidad de emoción	0.15	Limita cuánto puede modificar a p_MBI	Evita que la imagen domine la inferencia final
Valor neutro del texto	Valor asignado cuando no existe texto o no es posible obtener clasificación confiable	0.5	Neutraliza el efecto de la modalidad textual	Preserva la estabilidad del modelo
Valor neutro de la emoción	Valor asignado cuando no existe imagen o no hay detección facial confiable	0.5	Neutraliza el efecto de la modalidad visual	Preserva la estabilidad del modelo
Estrategia utilizada: Delta acotado	La probabilidad base p_MBI se ajusta con sentimiento y emoción centrados en 0.5 y limitados por cap_sent y cap_emo	$p_{\{final\}} = p_{\{MBI\}} + \delta_s + \delta_e$	Estrategia real utilizada en el prototipo prioriza el MBI y añade evidencia multimodal de forma controlada	Corresponde a la configuración programada por defecto

Nota. En la implementación del prototipo, la estrategia documentada y utilizada en la demostración corresponde a Delta acotado. En esta lógica, la probabilidad base $P_{\{mbi\}}$ es corregida suavemente por las modalidades de sentimiento y emoción a partir de su desviación respecto al valor neutro 0.5, con límites máximos definidos por cap_sent y cap_emo. En la interfaz se fijan por defecto los deslizadores en valores de 0.15 para ambos impactos máximos, lo que garantiza que las modalidades complementarias enriquezcan la inferencia sin desplazar el papel central del instrumento MBI.

Figura 8

Esquema visual de la ecuación multimodal y del efecto de los pesos o del delta acotado sobre la probabilidad final.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Diseño e implementación del prototipo funcional

La fase aplicada del trabajo de campo culminó con la construcción de un prototipo funcional en Streamlit. La aplicación fue concebida como una interfaz utilizable en entorno local para evaluación individual, consulta histórica y simulación del flujo de inferencia. Su desarrollo tuvo el propósito de demostrar que los hallazgos del trabajo de campo podían traducirse en una solución operativa y no únicamente en un análisis académico.

Arquitectura general en Streamlit

El prototipo se organiza en tres pestañas principales: Evaluación (Empleado), Histórico (RRHH) y Simulador (stream). En la pestaña de evaluación, el usuario responde los 22 ítems del MBI, puede añadir un comentario opcional y puede cargar una imagen opcional. A partir de esos

insumos, el sistema calcula $EE_{\{total\}}$, $DP_{\{total\}}$ y $RP_{\{total\}}$, estima la probabilidad base del componente MBI, obtiene la contribución de la modalidad textual y, si aplica, estima el score emocional.

La aplicación también permite seleccionar explícitamente el tipo de inferencia deseada: solo MBI, solo sentimiento, solo emoción, ensamble MBI + sentimiento, ensamble MBI + emoción, ensamble sentimiento + emoción, o ensamble completo MBI + sentimiento + emoción. Esta flexibilidad es útil en una tesis porque permite ilustrar de forma comparativa cómo cambia la probabilidad final cuando se activan o desactivan modalidades específicas.

Interpretación de scores y niveles en la interfaz

Cada resultado se expresa como probabilidad de burnout en escala de 0 a 1 y como un nivel cualitativo. En el código del sistema se definieron tres umbrales de interpretación: nivel ALTO para probabilidades iguales o superiores a 0,70; nivel MEDIO para probabilidades entre 0,40 y 0,69; y nivel BAJO para probabilidades inferiores a 0,40. Esta decisión facilita la lectura operativa del resultado por usuarios no técnicos y permite conectar el componente analítico con reglas de alerta temprana.

Nivel = ALTO si $p \geq 0.70$

MEDIO si $0.40 \leq p < 0.70$

BAJO si $p < 0.40$

El diseño del prototipo prioriza la interpretabilidad. Además de mostrar la probabilidad final, la aplicación despliega los subtotales del MBI y conserva información sobre los componentes usados en el ensamble. Esto permite comprender no solo cuál fue la decisión, sino también qué tipo de evidencia contribuyó a ella.

Persistencia de información y uso de MongoDB

La persistencia de la solución se resolvió con MongoDB. La configuración de la base de datos se maneja mediante variables de entorno, entre ellas MONGO_DB, MONGO_URI, MONGO_COLL_ASSESS y MONGO_COLL_ALERTS. Este mecanismo evita fijar credenciales sensibles dentro del código y permite separar la lógica de aplicación de la lógica de despliegue.

La aplicación utiliza dos colecciones principales: BurnoutAssessments y BurnoutAlerts. En la primera se almacenan las evaluaciones individuales, incluyendo identificador del empleado, marca temporal en UTC, modelo utilizado, probabilidad de burnout, nivel de riesgo, subtotales EE, DP y RP, probabilidades de los componentes MBI, sentimiento y emoción, ítems respondidos y, cuando existe, el comentario textual y los metadatos emocionales. En la segunda se almacenan las alertas emitidas, con el fin de sostener la lógica de seguimiento y control de repetición. MongoDB cumple una función más amplia que la de simple depósito de información. La aplicación consulta el histórico del empleado para identificar cambios respecto a mediciones previas, construir rachas de resultados altos y decidir si corresponde generar una nueva alerta. En este sentido, la base de datos participa directamente en el flujo de negocio del sistema y en la materialización del objetivo preventivo de la investigación.


Reglas de alerta y lógica operativa

En la barra lateral del prototipo se parametrizan las reglas de alerta. El sistema permite ajustar el umbral de probabilidad alta, el salto mínimo respecto a la medición anterior y el número de resultados altos consecutivos necesarios para activar una alerta por racha. En la configuración observada, el umbral de probabilidad alta se inicializa en 0,70, el delta respecto a la medición anterior en 0,15 y la racha de valores altos en tres eventos. Adicionalmente, la integración con Teams contempla un mecanismo de enfriamiento temporal para evitar notificaciones repetitivas en intervalos muy cortos.

Esta lógica muestra que el proyecto no terminó en un modelo matemático. La propuesta avanzó hasta una capa de operación, donde las predicciones se traducen en eventos accionables. Por ello, el software constituye un resultado sustantivo del trabajo de campo: integra captura de información, inferencia, persistencia, seguimiento histórico y reglas de activación.

Figura 9

Arquitectura técnica del prototipo, mostrando flujo entre Streamlit, modelos predictivos, MongoDB y sistema de alertas.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Tabla 12

Campos principales almacenados en las colecciones BurnoutAssessments y BurnoutAlerts.

Colección	Campo principal	Tipo de dato / formato	Descripción funcional	Observación
BurnoutAssessments	timestamp_utc	Fecha-hora / ISO UTC	Marca temporal del momento en que se ejecuta la evaluación	Permite ordenar y consultar el histórico
BurnoutAssessments	employee_id	Texto	Identificador del empleado evaluado	Campo clave para trazabilidad individual
BurnoutAssessments	PartitionKey	Texto	Clave de partición asociada al empleado	Facilita compatibilidad con esquemas tipo Cosmos/Atlas
BurnoutAssessments	RowKey	Texto	Identificador único del registro	Se genera como clave única por evaluación
BurnoutAssessments	model_used	Texto	Modelo principal utilizado en la inferencia	Indica si la salida corresponde a MBI o a un ensamble
BurnoutAssessments	prob_burnout	N Numérico [0,1]	Probabilidad final estimada de burnout	Salida principal del sistema
BurnoutAssessments	nivel	Texto categórico	Nivel interpretativo del resultado (BAJO, MEDIO o ALTO)	Se deriva de la probabilidad final
BurnoutAssessments	alerta	Booleano	Indica si la evaluación activó o no una alerta	Se usa en la lógica de negocio
BurnoutAssessments	motivos	Texto o lista	Razones asociadas a la activación de la alerta	Se normaliza para visualización histórica

Colección	Campo principal	Tipo de dato / formato	Descripción funcional	Observación
BurnoutAssessments	p_mbi	Númerico [0,1]	Probabilidad base del componente MBI	Evidencia psicométrica principal
BurnoutAssessments	p_sent	Númerico [0,1]	Probabilidad derivada del análisis de sentimiento	Evidencia textual complementaria
BurnoutAssessments	p_emo	Númerico [0,1]	Probabilidad derivada del análisis emocional facial	Evidencia visual complementaria
BurnoutAssessments	i1-i22	Entero (0-6)	Respuestas individuales a los 22 ítems del MBI	Se guardan como parte del registro evaluado
BurnoutAssessments	comment_text	Texto	Comentario textual ingresado por el usuario	Se almacena solo si fue suministrado
BurnoutAssessments	sent_feat	Estructura / diccionario	Características derivadas del análisis de sentimiento	Se almacena junto al comentario cuando aplica
BurnoutAssessments	emo_face_detected	Booleano	Indica si se detectó rostro en la imagen	Metadato de la modalidad emocional
BurnoutAssessments	emo_dominant	Texto	Emoción dominante detectada por DeepFace	Metadato de la modalidad emocional
BurnoutAlerts	timestamp_utc	Fecha-hora / ISO UTC	Marca temporal de la alerta generada	Permite trazabilidad temporal
BurnoutAlerts	teams_sent	Booleano	Indica si la alerta fue enviada a Teams	Soporta control operativo del sistema
BurnoutAlerts	teams_status	Texto	Estado o mensaje de resultado del envío a Teams	Útil para diagnóstico y auditoría

Colección	Campo principal	Tipo de dato / formato	Descripción funcional	Observación
BurnoutAlerts	employee_id	Texto	Identificador del empleado asociado a la alerta	Vincula la alerta con su evaluación
BurnoutAlerts	PartitionKey	Texto	Clave de partición asociada al empleado	Facilita compatibilidad con el esquema de almacenamiento
BurnoutAlerts	RowKey	Texto	Identificador único de la alerta	Permite unicidad del documento
BurnoutAlerts	model_used	Texto	Modelo principal que originó la alerta	Relaciona la alerta con la inferencia
BurnoutAlerts	prob_burnout	Numérico [0,1]	Probabilidad estimada de burnout al momento de la alerta	Resume la magnitud del riesgo
BurnoutAlerts	nivel	Texto categórico	Nivel de riesgo asociado a la alerta	Corresponde a la clasificación del sistema
BurnoutAlerts	motivos	Texto o lista	Razones específicas que dispararon la alerta	Explica por qué se activó
BurnoutAlerts	alerta	Booleano	Marca lógica de evento de alerta	En esta colección se registra como verdadero

Nota. La colección BurnoutAssessments se utiliza para almacenar el histórico completo de evaluaciones individuales, incluyendo tanto la inferencia final como los componentes del ensamble y, cuando están disponibles, los metadatos de texto e imagen. Por su parte, BurnoutAlerts registra únicamente los eventos de alerta, agregando campos operativos relacionados con el envío a Microsoft Teams, como teams_sent y teams_status.

Figura 10

Interfaz Streamlit con las pestañas Evaluación, Histórico y Simulador.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Análisis de resultados


La evidencia obtenida a lo largo del trabajo de campo permite interpretar los resultados en tres niveles. En el nivel psicométrico, el MBI demostró ser un instrumento consistente y estructuralmente coherente para capturar el fenómeno de interés. En el nivel estadístico, el análisis en SPSS mostró que agotamiento emocional y despersonalización son las dimensiones con mayor peso explicativo sobre la etiqueta de riesgo. En el nivel predictivo y aplicado, la comparación entre enfoques evidenció que el cuestionario aporta una base sólida, pero que la incorporación de modalidades adicionales enriquece la lectura del caso y abre la posibilidad de seguimiento operativo.

La principal fortaleza de la propuesta radica en que no enfrenta artificialmente el método tradicional y el método basado en machine learning como si fueran excluyentes. Por el contrario, la tesis muestra que ambos enfoques pueden complementarse. El análisis tradicional aporta interpretabilidad, validación psicométrica y capacidad explicativa. El aprendizaje automático aporta clasificación, escalabilidad e integración computacional. Por último, el enfoque multimodal añade contextualización, sensibilidad a señales heterogéneas y potencial de alerta temprana.

También es importante reconocer las limitaciones. La base original de campo fue relativamente pequeña, y por ello fue necesario recurrir a una ampliación Monte Carlo para robustecer el experimento. Este hecho no debilita el capítulo; al contrario, fortalece su honestidad metodológica. La investigación no presenta los resultados ideales de la muestra semilla como verdad definitiva, sino como señal de que debía ampliarse el entorno de evaluación. Esa decisión es consistente con una tesis rigurosa y con una lectura responsable del riesgo de sobreajuste.

Desde esta perspectiva, la hipótesis de trabajo recibe respaldo razonable: un sistema predictivo multimodal puede mejorar funcionalmente la capacidad de detección del burnout frente a esquemas basados solo en encuestas, no porque anule el valor del MBI, sino porque añade contexto, seguimiento histórico e integración de señales adicionales. La mejora, por tanto, no debe entenderse únicamente en términos de exactitud numérica, sino también en términos de capacidad operativa, interpretabilidad y prevención temprana.

Figura 11
Comparación conceptual y metodológica entre enfoque tradicional, monomodal y multimodal.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

Propuesta de solución a la problemática

Situación actual

La situación actual observada en el campo de aplicación es que la detección del burnout suele depender de instrumentos aislados, aplicados de forma episódica y analizados posteriormente. Ese esquema es útil para diagnóstico, pero limitado para prevención temprana, seguimiento longitudinal y actuación oportuna. Además, cuando el análisis se apoya en muestras pequeñas o en escenarios con poca variabilidad, existe riesgo de sobrestimar el desempeño de los modelos predictivos.

Oportunidades identificadas

Los hallazgos del estudio muestran oportunidades claras de mejora. La primera consiste en conservar el valor del MBI como instrumento validado sin restringirse a una lectura estática del cuestionario. La segunda consiste en incorporar señales complementarias que aporten contexto, especialmente lenguaje escrito y expresión emocional facial. La tercera consiste en materializar el análisis en una herramienta utilizable por personal no técnico, con base de datos histórica y reglas configurables de alerta.


Propuesta de solución

Como respuesta a la problemática se desarrolló un sistema predictivo multimodal implementado en Streamlit, con persistencia en MongoDB e integración de modelos para MBI, sentimiento y emoción. El sistema permite evaluación individual, consulta histórica por parte de RR. HH., simulación de inferencias y activación de alertas tempranas cuando se cumplen reglas previamente definidas. Su valor no radica únicamente en estimar una probabilidad, sino en convertir esa probabilidad en una decisión interpretable y registrable a lo largo del tiempo.

En términos de aporte al objetivo general, la propuesta demuestra que la detección del burnout puede pasar de un esquema retrospectivo y exclusivamente survey-based a un sistema integrador, interpretable y accionable. El MBI conserva su papel como fundamento del análisis, pero deja de ser la única fuente de información. Al integrarse con texto, imagen, persistencia histórica y alertas configurables, se transforma en el núcleo de una solución preventiva con potencial de aplicación en entornos laborales reales.

Figura 12

Arquitectura final de la solución propuesta, incluyendo captura de datos, modelos, MongoDB, histórico y alertas.



Nota. Figura elaborada por el autor con apoyo de inteligencia artificial generativa, con fines ilustrativos.

La **Figura 13** presenta la arquitectura final de la solución propuesta, integrando de manera secuencial y coherente todas las etapas desarrolladas en la investigación, desde la recolección inicial de los 110 registros obtenidos mediante el cuestionario Maslach Burnout Inventory (MBI), pasando por la construcción del dataset semilla, la ampliación del escenario experimental mediante simulación Monte Carlo hasta 5.000 registros, el análisis estadístico y predictivo realizado con herramientas de machine learning, y finalmente la implementación operativa del prototipo multimodal. De esta manera, la figura sintetiza el flujo completo del sistema, mostrando cómo la información capturada en campo se transforma en una solución tecnológica funcional capaz de procesar entradas multimodales, almacenar resultados en MongoDB, gestionar el histórico de evaluaciones y emitir alertas tempranas orientadas a la detección del síndrome de burnout.

Desde la **Figura 14** hasta la **Figura 24**, se muestra un conjunto de capturas representativas del funcionamiento real del prototipo desarrollado. En ellas se observa la interfaz de simulación y evaluación, la configuración de ensambles multimodales, la presentación de resultados, el almacenamiento en MongoDB y el envío automatizado de alertas en Microsoft Teams. Asimismo, se ilustran las vistas destinadas al empleado, al personal de recursos humanos y al uso demostrativo del sistema.

Figura 14

Panel general del prototipo con diagnóstico de conexión, reglas de alerta y métricas del modelo




Figura 15

Vista del módulo de evaluación del empleado con diligenciamiento del cuestionario MBI de 22 ítems

The screenshot displays a web application interface for employee evaluation. On the left, there is a sidebar with navigation options: 'Reglas de alerta', 'Notificación a Teams (RRHH)', 'Estado del modelo', and 'Historial de RRHH'. The main content area is titled '1) Responder cuestionario MBI (0-6)' and shows a list of 22 items with corresponding Likert scale responses (e.g., 'Nunca', 'A veces', 'Frecuente'). The interface is clean and professional, with a light blue header and a white background for the content area.

Figura 16

Vista del módulo histórico de RRHH con registro de evaluaciones y alertas generadas

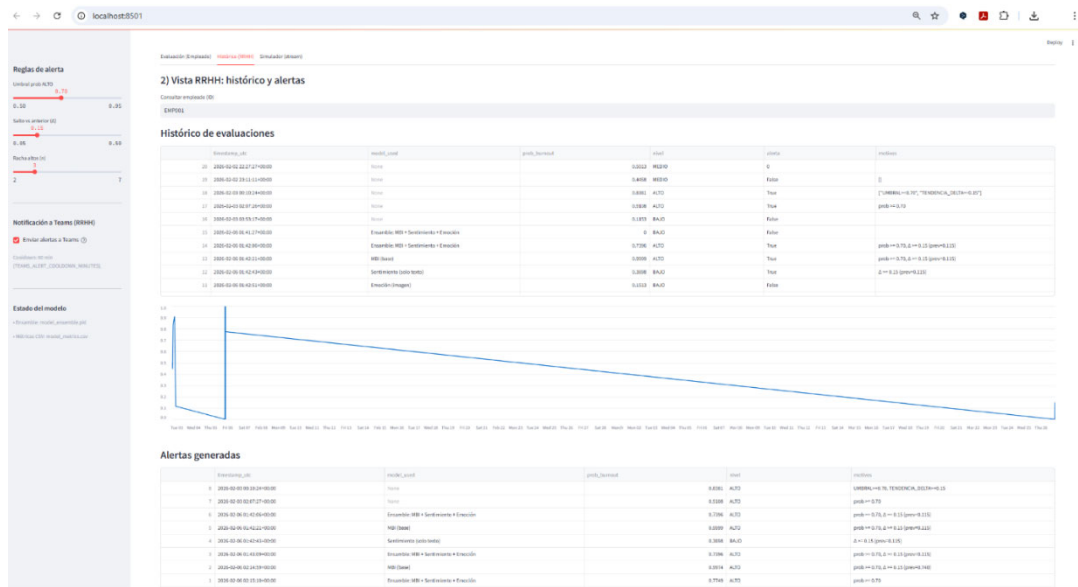


Figura 17

Vista del módulo simulador para ejecución de pruebas automáticas del flujo de evaluación




Figura 18

Pantalla de configuración de evaluación multimodal con carga de imagen, comentario de texto y parámetros del ensamble

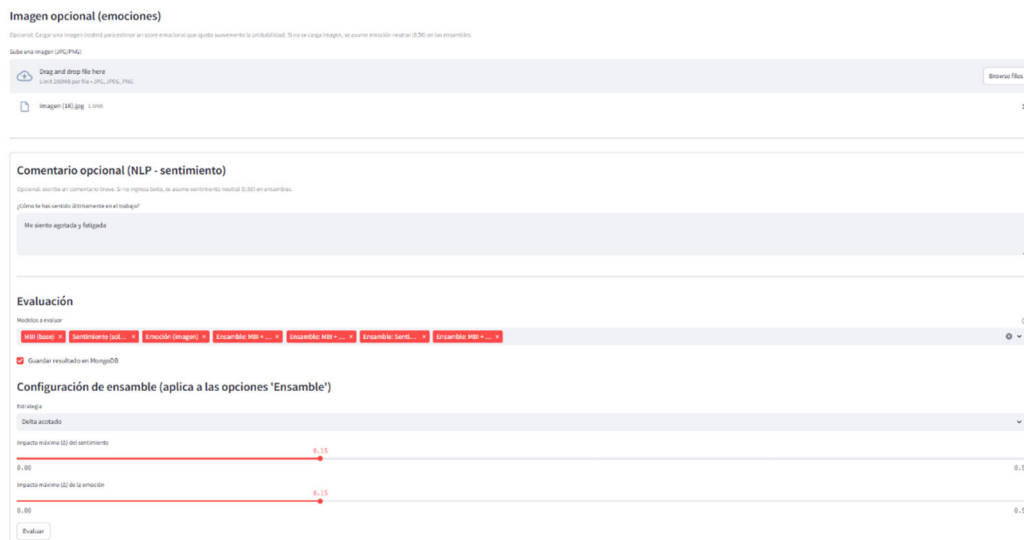


Figura 19

Selección de modelos de evaluación disponibles en la interfaz del prototipo




Figura 20
Resultados de la evaluación multimodal con probabilidades estimadas, niveles de riesgo y activación de alertas

Evaluación completada.		
Resultados		
MBI (base)		
Probabilidad burnout	EE, total	36
0.984	DP, total / RP, total	24 / 36
Nivel		
ALTO		
Sentimiento (solo texto)		
Probabilidad burnout	EE, total	36
0.634	DP, total / RP, total	24 / 36
Nivel		
MEDIO		
Emoción (imagen)		
Probabilidad burnout	EE, total	36
0.508	DP, total / RP, total	24 / 36
Nivel		
MEDIO		
Ensamble: MBI + Sentimiento		
Probabilidad burnout	EE, total	36
1.000	DP, total / RP, total	24 / 36
Nivel		
ALTO		
Estrategia: Detección		
Ensamble: MBI + Emoción		
Probabilidad burnout	EE, total	36
0.992	DP, total / RP, total	24 / 36
Nivel		
ALTO		
Estrategia: Detección		
Ensamble: Sentimiento + Emoción		
Probabilidad burnout	EE, total	36
0.642	DP, total / RP, total	24 / 36
Nivel		
MEDIO		
Estrategia: Detección		
Ensamble: MBI + Sentimiento + Emoción		
Probabilidad burnout	EE, total	36
1.000	DP, total / RP, total	24 / 36
Nivel		
ALTO		
Estrategia: Detección		
ALERTA generada según reglas actuales: prob == 0.70		
Alerta enviada a Teams (RRHH)		
Guardado en MongoDB.		

Figura 21

Notificación de alerta enviada automáticamente al canal de Microsoft Teams




Figura 22

Vista general de la base de datos MongoDB con las colecciones BurnoutAssessments y BurnoutAlerts

The screenshot shows the MongoDB Data Explorer interface. On the left, the 'Data Explorer' sidebar is visible with a search bar and a tree view showing the database structure. The main area displays a table of collections for the 'burnout_db' database. The table has columns for 'Collection name', 'Properties', 'Storage size', 'Data size', 'Documents', 'Avg. document size', 'Indexes', and 'Total index size'. Two collections are listed: 'BurnoutAlerts' and 'BurnoutAssessments'.

Collection name	Properties	Storage size	Data size	Documents	Avg. document size	Indexes	Total index size
BurnoutAlerts	-	45.06 kB	20.83 kB	63	330.00 B	5	184.32 kB
BurnoutAssessments	-	110.69 kB	88.74 kB	147	610.00 B	5	208.90 kB

Figura 23

Registro de una alerta almacenada en la colección BurnoutAlerts de MongoDB





Figura 24

Registro de una evaluación almacenada en la colección BurnoutAssessments de MongoDB



La evidencia visual presentada confirma que la solución propuesta fue implementada de forma integral y operativa, articulando captura de datos, procesamiento multimodal, almacenamiento persistente y mecanismos de alerta. Desde una perspectiva metodológica, estas capturas fortalecen la validez aplicada del trabajo, ya que demuestran que el sistema predictivo no solo fue diseñado y evaluado sobre conjuntos de datos, sino que además se materializó en un prototipo funcional capaz de apoyar procesos de monitoreo y detección temprana del burnout en contextos organizacionales.

Cierre del capítulo

El trabajo de campo presentado en este capítulo ha permitido documentar la trayectoria completa de la investigación: desde la recolección inicial de encuestas mediante el MBI hasta la construcción de un prototipo funcional capaz de combinar información estructurada y no estructurada. En ese recorrido se integraron medición psicométrica, depuración de datos, modelado estadístico, simulación Monte Carlo, clasificación mediante machine learning y diseño de una solución tecnológica con persistencia y reglas de alerta.

En consecuencia, el trabajo de campo no debe entenderse únicamente como la etapa de obtención de información, sino como el espacio donde se demostraron la viabilidad, la coherencia metodológica y la aplicabilidad del sistema propuesto. Los resultados obtenidos proporcionan una base sólida para los capítulos de discusión, conclusiones y trabajo futuro, donde podrá profundizarse en los alcances del modelo, sus limitaciones y las posibilidades de expansión con nuevas muestras reales y despliegues de mayor escala.

Discusión

Los resultados obtenidos en esta investigación permiten sostener que el fenómeno del burnout pudo ser caracterizado de manera consistente a partir del cuestionario Maslach Burnout Inventory (MBI), y que esta base psicométrica fue suficiente para estructurar un sistema predictivo con alcances descriptivos, inferenciales y aplicados. Sin embargo, la interpretación de estos hallazgos debe hacerse con cautela metodológica. El valor del estudio no reside únicamente en haber alcanzado altos niveles de desempeño en clasificación, sino en haber mostrado, de manera transparente, las tensiones entre la medición tradicional, el modelado predictivo y la implementación de una solución tecnológica multimodal. En ese sentido, la discusión no debe limitarse a afirmar que el sistema funciona, sino a precisar en qué condiciones, con qué alcance y bajo qué restricciones de validez lo hace (Maslach & Jackson, 1981) (Maslach C. S., 2001)

En primer lugar, el análisis del MBI y del conjunto Monte Carlo confirmó que las tres dimensiones del síndrome conservaron el comportamiento esperado teóricamente. En el dataset ampliado a 5.000 registros, el agotamiento emocional presentó una media de 29,65, la despersonalización una media de 15,93 y la realización personal una media de 27,47; además, la consistencia interna por subescala fue aceptable a buena, con coeficientes alfa de Cronbach de 0,811 para EE, 0,706 para DP y 0,787 para RP. A esto se sumó un patrón correlacional coherente: $EE_{\{total\}}$, se asoció positivamente con Burnout_alto ($\rho = 0,736$), $DP_{\{total\}}$ también mostró asociación positiva ($\rho = 0,509$) y $RP_{\{total\}}$ mantuvo una relación negativa ($\rho = -0,149$). Desde el punto de vista conceptual, estos hallazgos son compatibles con la literatura clásica del burnout, según la cual el agotamiento representa el núcleo más visible del síndrome y la

realización personal opera como dimensión protectora o inversamente relacionada con la afectación laboral (Cronbach, 1951) (Maslach C. S., 2001)

Un aspecto importante es que los resultados estadísticos del conjunto Monte Carlo corrigieron parcialmente una debilidad que aparecía en la muestra semilla. Mientras el borrador inicial de discusión sugería que la confiabilidad del instrumento había sido inferior a lo esperado, el análisis posterior mostró que, al menos sobre el dataset ampliado, la estructura del MBI se mantuvo operativamente estable. Esto no significa que el instrumento quede exento de limitaciones, pero sí permite afirmar que el problema principal del estudio no estuvo en la incoherencia del MBI, sino en la insuficiencia del tamaño y la variabilidad del conjunto original para sostener inferencias robustas. Desde una perspectiva de tesis, este punto es crucial, porque desplaza la discusión desde la supuesta debilidad del instrumento hacia la necesidad de fortalecer el diseño experimental y la generalización del modelo.

En segundo lugar, los modelos monomodales entrenados exclusivamente con la información del MBI mostraron un comportamiento llamativo. Random Forest y SVM alcanzaron métricas perfectas sobre la muestra semilla, mientras que la regresión logística obtuvo un desempeño muy alto, aunque no absoluto. En principio, esto podría interpretarse como evidencia de que el MBI posee una gran capacidad discriminativa; sin embargo, una lectura metodológicamente más rigurosa sugiere otra cosa. Cuando un conjunto pequeño produce exactitudes de 1,000 y valores perfectos de recall, F1 y AUC-ROC, lo razonable no es asumir superioridad predictiva sin reservas, sino considerar la posibilidad de sobreajuste, baja heterogeneidad o separabilidad artificialmente nítida entre clases. Este riesgo es consistente con

la teoría del aprendizaje automático: un modelo puede aprender muy bien las regularidades de una muestra pequeña sin que ello implique una buena capacidad de generalización fuera de ella (Goodfellow, 2016).

La decisión de ampliar el escenario experimental mediante simulación Monte Carlo fue, por tanto, metodológicamente acertada. No se trató de reemplazar la evidencia empírica, sino de construir un entorno más exigente para evaluar si los patrones observados en los 110 casos iniciales persistían al aumentar la variabilidad. El valor de esta estrategia radica en que permitió pasar de un conjunto pequeño, posiblemente demasiado homogéneo, a un escenario de 5.000 registros con balance de clases, mayor dispersión y mejores condiciones para análisis estadísticos y comparativos. Aun así, esta misma decisión introduce una tensión que debe reconocerse abiertamente: el dataset sintético fortaleció la estabilidad experimental, pero no equivale a nueva evidencia empírica independiente. En otras palabras, mejoró la validez interna del contraste entre métodos, pero no resuelve por sí mismo la validez externa del estudio.

En tercer lugar, el enfoque multimodal constituye el aporte más innovador del proyecto, pero también el que exige mayor prudencia interpretativa. La arquitectura implementada integró una probabilidad base derivada del MBI $P_{\{mbi\}}$ con una señal de sentimiento textual $p_{\{sent\}}$ y una señal emocional visual $p_{\{emo\}}$, usando como estrategia principal el esquema de delta acotado, en el cual las modalidades complementarias ajustan suavemente la probabilidad base sin desplazarla por completo. Además, cuando no existía texto o imagen válida, el sistema empleó un valor neutro de 0,5, lo que permitió mantener estabilidad de inferencia y evitar decisiones extremas por ausencia de datos. Desde el punto de vista de ingeniería, esta solución es valiosa

porque combina interpretabilidad, robustez operativa y flexibilidad de uso. Desde el punto de vista científico, se alinea con la literatura sobre affective computing y análisis multimodal, que subraya el potencial de combinar señales textuales y visuales para enriquecer la lectura del estado afectivo de una persona (Pérez, 2021) (Picard, 1997) (Poria, 2017)

No obstante, aquí aparece una de las limitaciones más importantes del estudio. Aunque el prototipo multimodal fue funcional y su lógica de integración está bien resuelta, la evidencia multimodal utilizada para validar su superioridad no provino de una recolección amplia y naturalista de texto e imagen en condiciones reales de trabajo, sino de una construcción simulada o controlada. Por ello, afirmar que el enfoque multimodal supera de manera concluyente al enfoque monomodal sería excesivo. Lo que sí puede sostenerse con mayor rigor es que la investigación demuestra la viabilidad técnica y conceptual de un sistema multimodal para burnout y ofrece una prueba de principio convincente, pero no una validación definitiva en condiciones ecológicas reales. Esta distinción es importante para no sobredimensionar el alcance de los resultados.

La implementación del prototipo en Streamlit, con almacenamiento en MongoDB y generación de alertas, añade una dimensión aplicada que fortalece la contribución del trabajo. A diferencia de estudios que se quedan en la comparación algorítmica, aquí se avanzó hasta un sistema operativo con módulos de evaluación, histórico, simulación y notificación. Esto demuestra que la propuesta no solo tiene coherencia analítica, sino también factibilidad tecnológica. Sin embargo, esta fortaleza aplicada no elimina la necesidad de validar la solución en contextos organizacionales reales, con usuarios reales, protocolos de consentimiento,

evaluación longitudinal y criterios institucionales para la activación de alertas. En su estado actual, el prototipo debe entenderse como una herramienta de apoyo a la detección temprana, no como un sustituto del juicio clínico, psicológico u organizacional.

En relación con la hipótesis de investigación, los resultados la apoyan de manera parcial y razonada, pero no permiten darla por confirmada en términos absolutos. La hipótesis sostenía que un sistema predictivo multimodal mejora la capacidad de detectar burnout frente a métodos basados solo en encuestas. La evidencia del proyecto favorece esta idea en tres sentidos: primero, el sistema integra más fuentes de información que el enfoque tradicional; segundo, la arquitectura funcional demuestra que esa integración puede llevarse a una aplicación real; y tercero, el modelo multimodal mostró una alta capacidad de separación en el entorno experimental construido. Sin embargo, esta mejora debe interpretarse como potencialmente superior y metodológicamente prometedora, más que como una superioridad ya demostrada en campo. La razón principal es que el estudio todavía no compara, sobre una misma cohorte real y multimodal, el desempeño del sistema frente a una medida externa independiente del MBI.

Las limitaciones del estudio son, por tanto, pertinentes y relevantes porque cuestionan directamente la validez potencial de los resultados. La primera limitación es el tamaño y la representatividad de la muestra semilla: alrededor de 110 participantes constituyen una base útil para explorar el problema, pero insuficiente para sostener generalizaciones a distintos sectores, cargos, culturas organizacionales o regiones. La segunda limitación es el uso de datos sintéticos para robustecer el experimento: aunque metodológicamente útil, este recurso no sustituye la necesidad de observaciones reales adicionales. La tercera limitación, especialmente importante,

es la posible circularidad parcial entre predictores y variable objetivo, dado que Burnout_alto fue operacionalizada a partir de las mismas dimensiones del MBI utilizadas luego como entrada del enfoque monomodal. Esto puede inflar el rendimiento aparente de los algoritmos, porque el modelo aprende a reproducir una etiqueta construida con sus propios insumos de origen. La cuarta limitación es la brecha ecológica entre el desempeño del sistema en un entorno controlado y su comportamiento real frente a ambigüedad lingüística, variación cultural, calidad desigual de imágenes y condiciones cambiantes del trabajo cotidiano. Finalmente, la quinta limitación es que el prototipo, aunque funcional, aún no ha sido sometido a una evaluación longitudinal de impacto organizacional (Goodfellow, 2016) (Poria, 2017)

En síntesis, la principal fortaleza de la investigación no está en haber alcanzado resultados perfectos, sino en haber identificado críticamente por qué esos resultados no podían aceptarse sin cuestionamiento y en haber construido una respuesta metodológica y tecnológica ante ese problema. El estudio muestra que el MBI sigue siendo una base válida para modelar el burnout, que los métodos de machine learning pueden capturar patrones relevantes del fenómeno y que la multimodalidad abre una ruta prometedora para enriquecer la detección temprana. Al mismo tiempo, la investigación reconoce que la validez final del sistema dependerá de estudios posteriores con muestras más amplias, datos multimodales reales, validación externa y seguimiento longitudinal. Por ello, la contribución del trabajo debe entenderse como un avance sólido de diseño, integración y prueba de concepto, más que como una solución definitivamente cerrada.

Conclusiones y Trabajo Futuro

Este apartado presenta las conclusiones derivadas de los resultados alcanzados y plantea las oportunidades de investigación que se desprenden del proyecto. Las conclusiones responden al problema formulado, se articulan con los objetivos del estudio y precisan el alcance real de la hipótesis, mientras que el trabajo futuro identifica las acciones necesarias para fortalecer la validez externa, la madurez tecnológica y la aplicabilidad organizacional de la propuesta.

Conclusiones

1. Respuesta al problema y cumplimiento del objetivo general

El estudio permitió demostrar que es viable desarrollar un sistema predictivo multimodal para la detección temprana del síndrome de burnout, articulando medición psicométrica, modelado predictivo e implementación tecnológica. La propuesta no se limitó a comparar algoritmos, sino que logró traducir la evidencia recolectada en un prototipo funcional con persistencia histórica y generación de alertas, lo que responde directamente al problema de cómo fortalecer la detección temprana más allá del uso exclusivo de encuestas.

2. Cumplimiento del objetivo específico de recolección y estructuración de datos

La aplicación del cuestionario Maslach Burnout Inventory a la muestra semilla permitió construir una base empírica coherente sobre las dimensiones de agotamiento emocional, despersonalización y realización personal. A partir de esta estructura se calcularon los subtotales

analíticos y la variable objetivo Burnout_alto, confirmando que el MBI conserva utilidad como instrumento base para describir, organizar y modelar el fenómeno del burnout.

3. Cumplimiento del objetivo específico de análisis estadístico y contraste tradicional

El análisis en IBM SPSS Statistics mostró que el método tradicional sigue siendo relevante para comprender el fenómeno. Las correlaciones y la regresión indicaron que el agotamiento emocional y la despersonalización son los componentes con mayor capacidad explicativa del riesgo alto, mientras que la realización personal opera en sentido inverso. Por tanto, una conclusión central es que el enfoque estadístico clásico no fue sustituido por la innovación propuesta, sino utilizado como línea base interpretativa y de validación psicométrica.

4. Cumplimiento del objetivo específico de modelado predictivo

Los modelos de machine learning entrenados con el MBI evidenciaron que las variables psicométricas contienen señal predictiva real. Sin embargo, las métricas perfectas observadas en la muestra semilla obligaron a introducir cautela metodológica, ya que podían reflejar baja variabilidad y riesgo de sobreajuste. La ampliación del escenario mediante simulación Monte Carlo hasta 5.000 registros fortaleció la evaluación y permitió analizar el comportamiento del sistema en condiciones más estables y heterogéneas.

5. Cumplimiento del objetivo específico de construcción multimodal y sistema de alertas

La integración de señales textuales y emocionales al componente base del MBI permitió construir un esquema multimodal interpretable, apoyado en una estrategia de delta acotado que conserva al MBI como eje principal y usa las modalidades complementarias como evidencia

adicional. A ello se sumó la implementación de un prototipo en Streamlit, con almacenamiento en MongoDB y reglas de alerta, lo que demuestra que la propuesta puede pasar del nivel analítico al nivel operativo y apoyar procesos de monitoreo y priorización de casos.

6. Validación de la hipótesis y alcance real de los resultados

Los resultados respaldan la hipótesis según la cual un sistema predictivo multimodal puede mejorar la capacidad de detección del burnout frente a métodos basados únicamente en cuestionarios. No obstante, esta validación debe formularse con precisión: la tesis demuestra una mejora conceptual, técnica y funcional dentro del entorno experimental construido, pero no una validación definitiva en condiciones reales a gran escala. En consecuencia, la principal contribución del estudio es haber dejado una prueba de concepto sólida, defendible y prometedora, cuya consolidación depende de nueva evidencia empírica.

Trabajo futuro

A partir de estos hallazgos, se identifican varias oportunidades de investigación y desarrollo que permitirían ampliar la robustez científica y la utilidad aplicada del sistema:

1. Recolección de datos multimodales reales

El paso más importante consiste en validar el modelo con texto, imagen y, eventualmente, otras señales obtenidas en condiciones reales de uso. Esto permitiría contrastar el sistema frente a ambigüedad lingüística, calidad variable de imagen, diversidad ocupacional y cambios temporales del estado emocional, superando así la dependencia actual de modalidades simuladas.

2. Ampliación de la muestra y evaluación longitudinal

Se recomienda aplicar la propuesta en empresas de distintos tamaños, sectores y modalidades de trabajo, con el fin de mejorar la representatividad del estudio. Diseños longitudinales también permitirían observar trayectorias de riesgo, evaluar la estabilidad de las predicciones y analizar si las alertas tempranas se relacionan con cambios reales en el bienestar laboral.

3. Fortalecimiento algorítmico, explicabilidad y gobernanza

Futuras versiones del sistema pueden incorporar modelos más avanzados de procesamiento de lenguaje natural y visión por computador, junto con técnicas de explicabilidad como SHAP o LIME. Este componente es clave para justificar las predicciones, aumentar la confianza institucional y establecer criterios éticos de uso, especialmente en escenarios organizacionales donde las decisiones deben ser transparentes y no punitivas.

4. Evolución del prototipo hacia una plataforma de apoyo organizacional

A futuro, el prototipo puede evolucionar hacia una plataforma con paneles diferenciados por rol, visualizaciones históricas más ricas, analítica agregada para RR. HH., seguimiento posterior a la alerta y mecanismos de intervención. De esta manera, la propuesta podría convertirse en una herramienta integral de apoyo a estrategias de prevención del riesgo psicosocial y de promoción del bienestar laboral.

El proyecto permitió responder al problema de investigación mediante una propuesta que combina rigurosidad metodológica y aplicación tecnológica. Al mismo tiempo, dejó claro que el siguiente paso no es repetir el experimento en los mismos términos, sino validarlo con datos

reales, mayor diversidad muestral y criterios de evaluación externa que consoliden la solución como una herramienta científicamente robusta y organizacionalmente útil.

Referencias

Listado consolidado de referencias de acuerdo con las Normas APA.

Abdelhadi, I. A., Mohammed, O. A., Babikir, S. K., Bedri, E. A., & Abdelhadi, A. A.

(Diciembre de 2025). *Is mental health contagious ? Depression, anxiety, stress and burnout among Mental health professionals in Sudan*. Obtenido de BioMed Central Ltd:

<https://www.scopus.com/record/display.uri?eid=2-s2.0->

85218500275&origin=resultslist&sort=plf-

f&src=s&sid=11760c09e61a3650e0a3b34d49df7981&sot=b&sdt=b&s=ALL%28burnout+AND+contagious%29&sl=29&sessionSearchId=11760c09e61a3650e0a3b34d49df7981

&relpos=1

Acosta, M., & Taline, A. (2020). *Síndrome de Burnout en el personal de salud en un servicio de referencia de enfermedades respiratorias. Itapúa-2020*. Obtenido de Semantic Scholar:

<https://www.semanticscholar.org/paper/S%C3%ADndrome-de-Burnout-en-el-personal-de-salud-en-un-Bogado-Acosta/4e9d0eef02e99fbf86daaa38f55625a8c16ae85d>

Alahmari, M., & Moaleem, M. (2022). *revalence of burnout in healthcare specialties: A*

systematic review using Copenhagen and Maslach Burnout Inventories. Obtenido de

<https://doi.org/10.12659/MSM.938798>

Alexandra M Shishkova, V. V. (2022). *The Burnout Concept as a Theoretical Framework for Investigating the Caregiving Impact of Relatives of Patients with Addictive Disorders*.

Obtenido de National Library of Medicine:

<https://pmc.ncbi.nlm.nih.gov/articles/PMC9833605/>

Alviery, D., Salvagioni, J., Melanda, F. N., Eumman, A., Gomzalez, A., Lopes, F., & Maffei, S.

(16 de Junio de 2017). *Physical, psychological and occupational*. Obtenido de

<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0185781>

Alzate, D. (2021). *Revisión bibliográfica sobre el síndrome de burnout en los profesionales de la salud en Latinoamérica según la literatura disponible en los últimos 5 años*. Obtenido de Universidad de Antiquia:

<https://bibliotecadigital.udea.edu.co/server/api/core/bitstreams/ca4f74db-1ba8-4ae5-93a8-6b647e7f9eac/content>

American Psychological Association. (2020). *American Psychological Association. (2020). Publication manual of the American Psychological Association (7th ed).*

Amos, Z. (2023). *The role of machine learning in predicting employee burnout*. Obtenido de HRTech247: <https://hrtech247.com/the-role-of-machine-learning-in-predicting-employee-burnout/>

Apiquian, A. (27 de abril de 2007). *El Síndrome del Burnout en las Empresas*. Obtenido de Universidad Anáhuac México Norte: <https://www.ucm.es/data/cont/media/www/pag-30022/sindrome%20burnout.pdf>

Baniadamdizaj, S., & Baniadamdizaj, S. (2023). rediction of Iranian EFL teachers' burnout level using machine learning algorithms and Maslach Burnout Inventory. *Iran Journal of Computer Science*, 6, 1–12. Obtenido de <https://doi.org/10.1007/s42044-022-00112-x>

Beltran, C., Moreno, M., & Salazar, J. (Agosto de 2016). *Confiabilidad y validación de la escala Maslach Burnout Inventory (Hss) en trabajadores del occidente de México*. Obtenido de Scielo: http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-55522016000200005

Bittar, M. C. (Julio de 2008). *INVESTIGACIÓN SOBRE “BURNOUT Y ESTILOS DE*

PERSONALIDAD EN ESTUDIANTES UNIVERSITARIOS. Obtenido de

https://fci.uib.es/digitalAssets/177/177915_2.pdf

Bizuneh, B., Markos Woldesemayat, E., Lucero, D. E., & Markos, T. (Diciembre de 2025).

Prevalence and associated factors of burnout syndrome among selected health care professionals at University Hospitals of Sidama Region and Southern, Ethiopia 2023.

Obtenido de BioMed Central Ltd: [https://www.scopus.com/record/display.uri?eid=2-](https://www.scopus.com/record/display.uri?eid=2-s2.0-85219597770&origin=resultslist&sort=plf-)

[s2.0-85219597770&origin=resultslist&sort=plf-](https://www.scopus.com/record/display.uri?eid=2-s2.0-85219597770&origin=resultslist&sort=plf-f&src=s&sid=11760c09e61a3650e0a3b34d49df7981&sot=b&sdt=b&s=TITLE-ABS-KEY%28burnout+prevalence%29&sl=22&sessionSearchId=11760c09e61a3650e0a3b34d49df7981&relpos=2)
[f&src=s&sid=11760c09e61a3650e0a3b34d49df7981&sot=b&sdt=b&s=TITLE-ABS-](https://www.scopus.com/record/display.uri?eid=2-s2.0-85219597770&origin=resultslist&sort=plf-f&src=s&sid=11760c09e61a3650e0a3b34d49df7981&sot=b&sdt=b&s=TITLE-ABS-KEY%28burnout+prevalence%29&sl=22&sessionSearchId=11760c09e61a3650e0a3b34d49df7981&relpos=2)
[KEY%28burnout+prevalence%29&sl=22&sessionSearchId=11760c09e61a3650e0a3b34](https://www.scopus.com/record/display.uri?eid=2-s2.0-85219597770&origin=resultslist&sort=plf-f&src=s&sid=11760c09e61a3650e0a3b34d49df7981&sot=b&sdt=b&s=TITLE-ABS-KEY%28burnout+prevalence%29&sl=22&sessionSearchId=11760c09e61a3650e0a3b34d49df7981&relpos=2)
[d49df7981&relpos=2](https://www.scopus.com/record/display.uri?eid=2-s2.0-85219597770&origin=resultslist&sort=plf-f&src=s&sid=11760c09e61a3650e0a3b34d49df7981&sot=b&sdt=b&s=TITLE-ABS-KEY%28burnout+prevalence%29&sl=22&sessionSearchId=11760c09e61a3650e0a3b34d49df7981&relpos=2)

Cabezas, R., Aguirre, C., Cabezas, J., & Ceballos, D. (15 de 02 de 2022). *Validez factorial del Maslach Burnout Inventory versión española en una población multiocupacional ecuatoriana*. Obtenido de Sapienza:

<https://journals.sapienzaeditorial.com/index.php/SIJIS/article/download/261/140/628>

Carretero Dios-H.Pérez, C. (2007). Normas para el desarrollo y revisión de estudios

instrumentales: consideraciones sobre la selección de tests en la investigación

psicológica. *International Journal of Clinical and Health Psychology*, 7(3), 863-882.

Colonnello, V., & Carnevali, L. (2021). Reduced recognition of facial emotional expressions in global burnout and burnout depersonalization in healthcare providers. *PeerJ*, 9, e10610.

Obtenido de <https://doi.org/10.7717/peerj.10610>

CorestratAI. (2024). *BERT and RoBERTa Based Sentiment Analysis*. Obtenido de CorestratAI

Strategic AI: <https://www.corestratai.com/post/comparative-study-on-bert-and-roberta-based-sentiment-analysis>

Creswell, J. W. (2014). *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches (4th ed.)*. SAGE Publications.

Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*.

datalab.io. (2023). *Facial Recognition and Emotion Analysis with Azure Face API*. Obtenido de <https://datalabs.io/facial-recognition-and-emotion-analysis-with-azure-face-api/>

Dehne, M., Roorda, D. L., Koomen, H., & Zee, M. (8 de Mayo de 2024). *nder pressure? Exploring the moderating and mediating role of principal–teacher relationships in primary and secondary school teachers’ burnout symptoms*. Obtenido de Springer Science and Business Media B.V.: <https://www.scopus.com/record/display.uri?eid=2-s2.0-85219653255&origin=resultslist&sort=plf-f&src=s&sot=b&sdt=b&s=TITLE-ABS-KEY%28burnout%29&sessionSearchId=11760c09e61a3650e0a3b34d49df7981&relpos=>

13

Escobar, A. (2023). *Job burnout prediction in two Colombian companies using communication patterns via email*. Obtenido de Repositorio Universidad de los Andes:

<http://hdl.handle.net/1992/43883>

Etecé, Equipo editorial. (24 de Diciembre de 2015). *20 Ejemplos de Hipótesis*. Obtenido de Enciclopedia de Ejemplos: <https://www.ejemplos.co/20-ejemplos-faciles-de-hipotesis/>

Farley, P. (2025). *What is the Azure AI Face service?* Obtenido de Microsoft Learn:

<https://learn.microsoft.com/en-us/azure/ai-services/computer-vision/overview-identity>

Field, A. (2018). *Discovering Statistics Using IBM SPSS Statistics (5th ed.)*. SAGE Publications.

Flick, U. (2018). *An Introduction to Qualitative Research (6th ed.)*. SAGE Publications.

Fórmica, N., Muñoz, C., & Rojas, Y. (2015). *Síndrome de Burnout en el personal de enfermería, en el servicio de Terapia Intensiva Pediátrica*. Obtenido de Escuela de Enfermería Sede: FMC: https://bdigital.uncu.edu.ar/objetos_digitales/10155/formica-natal.pdf

Freudenberger, H. J. (1974). Staff burn-out. *Journal of Social Issues*, 30(1), 159–165. Obtenido de <https://doi.org/10.1111/j.1540-4560.1974.tb00706.x>

Galliussi, G. (2020). *Síndrome de burnout y su relación a la antigüedad en el puesto de trabajo y el sexo en médicos de diferentes especialidades de la ciudad de Paraná*. Obtenido de Pontificia Universidad Católica de Argentina: <https://repositorio.uca.edu.ar/bitstream/123456789/11696/1/sindrome-burnou-relacion-antiguedad.pdf>

Garcéz, Y., & García, E. (28 de Junio de 2023). *Incidencia del Género en el Estrés Laboral y Burnout del Profesorado Universitario*. Obtenido de Semantic Scholar : <https://www.semanticscholar.org/paper/Incidencia-del-G%C3%A9nero-en-el-Estr%C3%A9s-Laboral-y-del-Garc%C3%A9s%E2%80%90Delgado-Garc%C3%ADa-%C3%81lvarez/d8bb17a0fe874c1e5930a1cbebe83f5c558da161>

Godoy, F. (Abril de 2025). *Quieres ver ejemplos de hipótesis? Pues, aquí los tienes*. Obtenido de Tesis y Masters: <https://tesisymasters.com.co/hipotesis-ejemplos/>

Goodfellow, I. B. (2016). *Deep Learning*. MIT Press.

Guevara Cazar, M. E. (2012). *Identificación del Burnout en profesionales de la salud y factores relacionados con este fenómeno, en el Área de salud N.4 - Hospital San Luis de Otavato, provincia de Imbaura*.

<https://dspace.utpl.edu.ec/bitstream/123456789/5209/3/GUEVARA%20CAZAR%20MARIA%20ELENA.pdf>.

Hermida Moreno, D. (2024). *Apoyo diagnóstico del Burnout con el uso del El Machine Learning*. Obtenido de Fundación Universitaria Konrad Lorenz:

<https://repositorio.konradlorenz.edu.co/entities/publication/72476876-5bd6-4414-9de3-2e08ef9bd457>

Hernández Sampieri, R. F. (2014). *Metodología de la investigación (6a ed.)*. McGraw-Hill.

Herrity, J. (2024). *9 Causes of Burnout (With Helpful Ways To Manage It)*. Obtenido de Indeed:

<https://www.indeed.com/career-advice/career-development/causes-of-burnout>

Igartua, M. (15 de Abril de 2024). *Síndrome de burnout de moderador de contenidos en línea como accidente de trabajo*. Obtenido de Semantic Scholar:

<https://www.semanticscholar.org/paper/S%C3%ADndrome-de-burnout-de-moderador-de-contenidos-en-Mir%C3%B3/f1cd8ca74fc9386d47793766eff4a677fd561cb5>

Interlogos. (2024). *Identify and prevent employee burnout*. Obtenido de

<https://www.intelogos.com/burnout>

John Brownridge, A. W. (2024). *The Digital Workplace Productivity*. Obtenido de

<https://www2.deloitte.com/us/en/blog/human-capital-blog/2024/measuring-hybrid-and-remote-workforce-productivity.html>

Karine, L., & Giraldo, M. (2015). *Prevalencia del síndrome de burnout en los funcionarios de la empresa municipal de servicios públicos de arauca emserpa e.i.c.e., e.s.p.* Obtenido de

<https://repository.ucc.edu.co/server/api/core/bitstreams/27b18995-0594-4641-8f29-671997b581ae/content>

Kerlinger, F. N. (2002). *Investigación del comportamiento: Métodos de investigación en ciencias sociales*. McGraw-Hill.

Kurpicz-Briki, M., & Merhbene, G. (2024). *Using natural language processing to find indication for burnout with text classification: From online data to real-world data*. Obtenido de [www.arXiv.com: https://doi.org/10.48550/arXiv.2409.14357](https://arxiv.org/abs/2409.14357)

Latus. (2023). *Buzz for burnout: wearables and early burnout detection*. Obtenido de Latus Health: <https://latusgroup.co.uk/buzz-for-burnout-wearables-and-early-burnout-detection/>

Lotero M, Y., & all. (12 de 2020). *SÍNDROME DE BURNOUT Y SU EFECTO EN EL BIENESTAR DE LOS TRABAJADORES DE LA EMPRESA CALZADO JULEISY S.A.S*. Obtenido de Politécnico Gran Colombiano: <https://alejandria.poligran.edu.co/bitstream/handle/10823/2668/TRABAJO%20FINAL.pdf?isAllowed=y&sequence=1>

Martínez, C., & Caballero, C. (Enero-Junio de 2016). *Validación del cuestionario Maslach Burnout Inventory-Student Survey (MBISS) en contexto académico colombiano*. Obtenido de CES Psicología, vol. 9, núm. 1, enero-junio, 2016, pp. i-xv Universidad CES Medellín, Colombia: <https://www.redalyc.org/pdf/4235/423545768002.pdf>

Martínez-Salgado, C. (2012). El muestreo en investigación cualitativa. Principios básicos y algunas controversias. En *Ciencia & Saude Coletiva* (págs. 17(3), 613-619).

Martins, J. (28 de Marzo de 2025). *Qué es el burnout: cómo identificarlo y prevenir el desgaste profesional*. Obtenido de Asana: <https://asana.com/es/resources/what-is-burnout>

Mascha Kurpicz-Briki, G. M. (22 de Septiembre de 2024). *Using Natural Language Processing to find Indication for Burnout with Text Classification: From Online Data to Real-World Data*. Obtenido de Cornell University: <https://arxiv.org/abs/2409.14357>

Maslach, C. S. (2001). Job burnout. *Annual Review of Psychology*, 52, 397–422.

Maslach, C., & Jackson, S. E. (1981). The measurement of experienced burnout. *Journal of Organizational Behavior*, 2(2), 99–113.

Maslach, C., & Leiter, M. (5 de Junio de 2016). Obtenido de

<https://pmc.ncbi.nlm.nih.gov/articles/PMC4911781/>

Maslach, C., Jackson, S., Schaufeli, W., & Schwab, R. (2025). *Maslach Burnout Inventory™ (MBI)*. Obtenido de Ming Garden: <https://www.mindgarden.com/117-maslach-burnout-inventory-mbi>

Matinez Perez, A. (Septiembre de 2010). *EL SÍNDROME DE BURNOUT. EVOLUCIÓN CONCEPTUAL Y ESTADO ACTUAL DE LA CUESTIÓN*. Obtenido de VivatAcademia: <https://www.redalyc.org/pdf/5257/525752962004.pdf>

Millán, L. (09 de Octubre de 2024). *Liderazgo y cultura empresarial para evitar el burnout*. Obtenido de OpenWebinars: <https://openwebinars.net/blog/liderazgo-y-cultura-empresarial-para-evitar-el-burnout/>

Montero, I. &. (2007). Guía para nombrar los estudios de investigación en Psicología. *International Journal of Clinical and Health Psychology*, 7(3), 847-862.

Navarro, A. (2024). *Can AI help prevent employee burnout?* Obtenido de People Matters: <https://www.peplemattersglobal.com/article/life-at-work/can-ai-help-prevent-employee-burnout-42443>

Ospina H, D. A. (19 de 01 de 2024). *La inteligencia artificial también es una opción contra el fenómeno laboral, 'burnout'*. Obtenido de LR: <https://www.larepublica.co/salud-ejecutiva/soluciones-con-la-inteligencia-artificial-al-burnout-3783591>

Oviedo C, G. A., & Villamizar F, J. E. (01 de 12 de 2023). *Síndrome de burnout en el contexto*

del desgaste profesional desde la perspectiva nacional e internacional: una revisión

bibliográfica. Obtenido de Unipaz, Vol. 7 Núm. 2 (2023): Revista de Investigaciones,

Desarrollo e Innovación en Ingenierías:

<https://unipaz.edu.co/revistas/RIDING/article/view/358>

Palma, A., Marchant, F., Vera, V., & Larraín, M. (01 de Enero de 2025). *Burnout y satisfacción*

laboral en trabajadores/as sociales de la Región de Ñuble, Chile. Obtenido de

Prospectiva Revista de Trabajo Social e Intervención Social:

<https://revistapropectiva.univalle.edu.co/index.php/prospectiva/article/view/13798>

Patlán, J. (29 de Noviembre de 2013). *Efecto del burnout y la sobrecarga en la calidad de vida*

*en el trabajo*1. Obtenido de Elsevier Doyma:

<http://www.scielo.org.co/pdf/eg/v29n129/v29n129a08.pdf>

Patton, M. Q. (2015). *Qualitative Research & Evaluation Methods (4th ed.)*. SAGE Publications.

Pérez, J. M. (2021). *pysentimiento: A Python Toolkit for Opinion Mining and Social NLP Tasks*.

. Obtenido de arXiv : <https://arxiv.org/abs/2106.09462>

Picard, R. W. (1997). *Affective Computing*. MIT Press.

Polit, D. F. (2017). *Nursing Research: Generating and Assessing Evidence for Nursing Practice*

(10th ed.). Wolters Kluwer.

Poria, S. C. (2017). A review of affective computing: From unimodal analysis to multimodal

fusion. En *Information Fusion* (págs. 37, 98–125.).

Quarksup. (2024). *How can AI help identify signs of stress or burnout in employees?*. Obtenido

de [https://www.quarksup.com/en/how-can-ai-help-identify-signs-of-stress-or-burnout-in-](https://www.quarksup.com/en/how-can-ai-help-identify-signs-of-stress-or-burnout-in-employees/)

[employees/](https://www.quarksup.com/en/how-can-ai-help-identify-signs-of-stress-or-burnout-in-employees/)

Rhein, J. (26 de Abril de 2022). *Cómo redactar una hipótesis de investigación*. Obtenido de AJE

MPS: <https://www.aje.com/es/arc/how-to-write-a-research-hypothesis/>

Rivas, A. (2022). *Cómo hacer una hipótesis paso a paso*. Obtenido de NormasAPA:

<https://normasapa.in/como-hacer-una-hipotesis/>

Rodríguez, R., & De Rivas, S. (2011). *Los procesos de estrés laboral y desgaste profesional (burnout): diferenciación, actualización y líneas de intervención*. Obtenido de Scielo:

https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S0465-546X2011000500006

Rojas B, J. (Enero de 2020). *Prevención del síndrome de Burnout mediante programación neurolingüística soportada por la Web de las Cosas: Mapeo sistemático*. Obtenido de

Scielo: [http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-11292020000100035)

[11292020000100035](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-11292020000100035)

Sabori, L., & Hidalgo, L. (15 de 12 de 2014). *Síndrome de Burnout*. Obtenido de

<https://www.scielo.sa.cr/pdf/mlcr/v32n1/art14v32n1.pdf>

Saborio, L., & Murillo, L. H. (Marzo de 2015). *SÍNDROME DE BURNOUT*. Obtenido de

Medicina Legal de Costa Rica: <https://www.scielo.sa.cr/pdf/mlcr/v32n1/art14v32n1.pdf>

Schaufeli, W. B. (2009). Burnout: 35 years of research and practice. *Career Development International*, 14(3), 204-220.

Skaalvik, E. M., & Skaalvik, S. (Abril de 2009). *Does school context matter? Relations with teacher burnout and job satisfaction*. Obtenido de ScienceDirect:

<https://www.sciencedirect.com/science/article/pii/S0742051X08002163>

Slate Safety. (2025). *The Impact of Real-Time Alerts on Workplace Safety*. Obtenido de

<https://slatesafety.com/the-impact-of-real-time-alerts-on-workplace-safety/>

Soares, J., Lopes, R., Mendonça, P., Rodrigues, C., & Castro, J. (2023). *Use of the Maslach*

Burnout Inventory among public health care professionals: Scoping review. Obtenido de <https://doi.org/10.2196/44195>

Summers, P. (2024). *Digital Workplace Metrics: Measuring Employee Productivity*. Obtenido de Scalable: <https://www.scalable.com/blog/metrics-in-the-digital-workplace-how-to-accurately-and-objectively-measure-employee-productivity>

Tabachnick, B. G. (2019). *Using Multivariate Statistics (7th ed.)*. Pearson.

Tamburrino, Í. (s.f.). *¿Cómo formular la hipótesis de mi tesis?* Obtenido de Universidad de Chile: <https://aprendizaje.uchile.cl/recursos-para-leer-escribir-y-hablar-en-la-universidad/profundiza/profundiza-en-la-tesis/hipotesis/>

The Brussels Times. (2022). *Artificial intelligence tools to detect burnout*. Obtenido de <https://www.brusselstimes.com/235867/artificial-intelligence-tools-to-detect-burnout>

Universidad Excelsior. (2023). *Tipos de hipótesis de investigación*. Obtenido de Excelsior Inline Writing Lab: <https://owl.excelsior.edu/es/research/research-hypotheses/types-of-research-hypotheses/>

Van Zyl-Cillie, M., Bührmann, J., Blignaut, A., Demirtas, D., & Coetzee, S. (2024). A machine learning model to predict the risk factors causing feelings of burnout and emotional exhaustion amongst nursing staff in South Africa. *BMC Health Services Research*, 24, 1665. Obtenido de <https://doi.org/10.1186/s12913-024-12184-5>

Velázquez, D. V. (2009). *Síndrome de Burnout en Profesionales de la Salud en el Hospital General "Dr. Carlos Canseco"*. Tampico, Tamaulipas, México: <https://digibug.ugr.es/bitstream/handle/10481/2711/18487245.pdf?sequence=1&isAllowed=y>.

Vňuková et al, M. S. (2023). Burnout syndrome in the Czech Republic: The decreasing trend

over the years. *Frontiers in Public Health.*, Volume 11 - 2023 |

<https://doi.org/10.3389/fpubh.2023.1099528>.

Vorecol. (2024). *¿De qué manera la inteligencia artificial puede ayudar en la detección y*

prevención del burnout laboral? Obtenido de [https://vorecol.com/es/articulos/articulo-de-](https://vorecol.com/es/articulos/articulo-de-que-manera-la-inteligencia-artificial-puede-ayudar-en-la-deteccion-y-prevencion-del-burnout-laboral-113482)

[que-manera-la-inteligencia-artificial-puede-ayudar-en-la-deteccion-y-prevencion-del-](https://vorecol.com/es/articulos/articulo-de-que-manera-la-inteligencia-artificial-puede-ayudar-en-la-deteccion-y-prevencion-del-burnout-laboral-113482)

[burnout-laboral-113482](https://vorecol.com/es/articulos/articulo-de-que-manera-la-inteligencia-artificial-puede-ayudar-en-la-deteccion-y-prevencion-del-burnout-laboral-113482)

Walid Boussou, H. A. (2024). *RoBERTa Sentiment Analysis*. Obtenido de GitHub:

https://github.com/walidbosso/Roberta_Fine_Tuning_Sentiment_Analysis

Wikipedia, abril. (2025). *Occupational burnout*. Obtenido de

https://en.wikipedia.org/wiki/Occupational_burnout

Wikipedia, mayo. (2025). *Maslach Burnout Inventory*. Obtenido de

https://en.wikipedia.org/wiki/Maslach_Burnout_Inventory

World Health Organization. (2022). *WHO guidelines on mental health at work*. Obtenido de

<https://www.who.int/publications/i/item/9789240053052>

Anexos.

Los anexos presentados a continuación reúnen los materiales complementarios que sustentan el desarrollo metodológico, técnico y aplicado de la presente investigación. Su inclusión tiene como propósito ampliar la comprensión del lector sobre los instrumentos, bases de datos, procedimientos estadísticos y componentes tecnológicos utilizados en el diseño e implementación del sistema predictivo multimodal para la detección temprana del síndrome de burnout.

En esta sección se incorporan tanto los insumos utilizados durante el proceso de investigación como los productos técnicos derivados de la solución propuesta. En particular, se anexan el cuestionario aplicado para la recolección de datos, los resultados de la simulación estadística en IBM SPSS Statistics, las bases de datos empleadas en la fase empírica y sintética, así como la estructura principal del prototipo desarrollado en Streamlit. Estos anexos permiten dar trazabilidad al proceso investigativo y fortalecen la transparencia, replicabilidad y validez del estudio.

Lista de anexos

- Anexo A. Cuestionario Maslach Burnout Inventory (MBI). Instrumento de recolección de información utilizado en la investigación y base psicométrica del proyecto.
- Anexo B. Resultados de la simulación en IBM SPSS Statistics. Salidas estadísticas generadas a partir del análisis del dataset ampliado mediante simulación Monte Carlo.
- Anexo C. Dataset de la muestra inicial de 110 usuarios. Base de datos recolectada en campo mediante la aplicación del cuestionario MBI.

- Anexo D. Dataset de simulación Monte Carlo de 5.000 registros. Base de datos sintética generada a partir de la muestra inicial para ampliar el escenario experimental.
- Anexo E. Estructura de la solución desarrollada en Streamlit. Organización principal de archivos, scripts, carpetas y recursos técnicos del prototipo implementado.

A. Anexo. Cuestionario Maslach Burnout Inventory (MBI)

En este anexo se presenta el instrumento de recolección de información utilizado en la investigación, correspondiente al cuestionario Maslach Burnout Inventory (MBI) en la versión aplicada al estudio. Este instrumento constituye la base psicométrica del proyecto y permitió obtener la muestra inicial de participantes utilizada como semilla para el análisis posterior.

Nota. El cuestionario Maslach Burnout Inventory (MBI) fue adaptado mínimamente para la presente investigación mediante el reemplazo del término “alumnos/as” por “compañeros/as”, con el propósito de ajustarlo al contexto laboral general de los participantes. Esta adecuación tuvo un carácter exclusivamente contextual, por lo que se mantuvieron intactos la estructura del instrumento, los ítems, la escala de respuesta y la distribución original en sus tres subescalas.

Documentos entregados:

- A. Anexo. Cuestionario Maslach Burnout Inventory (MBI).pdf

B. Anexo. Resultados de la simulación en IBM SPSS Statistics

Este anexo contiene las salidas generadas en IBM SPSS Statistics a partir del análisis del dataset ampliado mediante simulación Monte Carlo. Incluye los principales resultados descriptivos, indicadores psicométricos, análisis de correlación y regresión empleados para contrastar el comportamiento estadístico del fenómeno estudiado.

Documentos entregados:

Carpeta: B. Anexo. Resultados de la simulación en IBM SPSS Statistics

- Carpeta: Data: burnout.sav
- Descriptives.pdf
- Frecuencias.pdf
- Alfa_de_Cronbash_DP.pdf
- Alfa_de_Cronbash_EE.pdf
- Alfa_de_Cronbash_RP.pdf
- Prueba de normalidad (Kolmogorov-Smirnov).pdf
- Correlaciones entre escalas.pdf
- Regresión logística (modelo predictivo en SPSS).pdf
- Descriptives.spv
- Frecuencias.spv
- Alfa_de_Cronbash_DP.spv
- Alfa_de_Cronbash_EE.spv
- Alfa_de_Cronbash_RP.spv
- Prueba de normalidad (Kolmogorov-Smirnov).spv

- Correlaciones entre escalas.spv
- Regresión logística (modelo predictivo en SPSS).spv

C. Anexo. Dataset de la muestra inicial de 110 usuarios

En este anexo se incluye la base de datos correspondiente a la muestra recolectada en campo, conformada por los registros obtenidos mediante la aplicación del cuestionario MBI. Este conjunto de datos funcionó como base empírica inicial del estudio y como insumo para la generación del dataset sintético posterior.

Documentos entregados:

- C. Anexo. Dataset de la muestra inicial de 110 usuarios.csv

D. Anexo. Dataset de simulación Monte Carlo de 5.000 registros

Este anexo presenta la base de datos sintética generada a partir de la muestra inicial mediante simulación Monte Carlo. El archivo incluye los 5.000 registros utilizados para fortalecer el escenario experimental, realizar análisis estadísticos más estables y comparar el desempeño de los modelos predictivos.

Documentos entregados:

- D. Anexo. Dataset de simulación Monte Carlo de 5.000 registros.csv

E. Anexo. Estructura de la solución desarrollada en Streamlit

En este anexo se documenta la organización general de los archivos y componentes que conforman el prototipo desarrollado en Streamlit para la detección temprana del síndrome de burnout. La estructura incluye scripts principales de ejecución, archivos de configuración, recursos del modelo entrenado, definición de ítems del cuestionario y dependencias requeridas para el funcionamiento del sistema.

La inclusión de este material permite evidenciar la implementación técnica de la solución propuesta y facilita la comprensión de la arquitectura empleada en el desarrollo del prototipo.

Archivos principales de la solución

- `app.py`: Archivo principal de la aplicación desarrollada en Streamlit.
- `train_model_con_emociones.py`: Script de entrenamiento del modelo con integración multimodal.
- `run_app.bat`: Archivo de ejecución local del prototipo.
- `requirements.txt`: Dependencias necesarias para el entorno de ejecución.
- `mbi_items_es.json`: Estructura de los ítems del cuestionario MBI en español.
- Carpeta `model`: Modelos entrenados y artefactos asociados.
- Carpeta `data`: Archivos de datos utilizados por la aplicación.
- `Dockerfile`: Archivo de configuración para despliegue en contenedores.
- `README.md`: Documento descriptivo del proyecto.

Documentos entregados:

Carpeta: E. Anexo. Estructura de la solución desarrollada en Streamlit

Subcarpeta: burnout-app:

- Carpeta Data: Métricas.png
- Carpeta Model: model_ensemble.pkl
- model_metrics.csv
- model_metrics.json
- app.py
- Dockerfile
- mbi_items_es.json
- README.md
- requirements.txt
- run_app.bat
- train_model_con_emociones.py