



**UNIVERSIDAD NACIONAL DE CHIMBORAZO**  
**FACULTAD DE INGENIERÍA**  
**CARRERA DE INGENIERÍA EN TECNOLOGÍAS DE LA INFORMACIÓN**

Desarrollo de una aplicación web para la evaluación de riesgo psicosocial en el ambiente  
laboral utilizando técnicas de machine learning.

**Trabajo de Titulación para optar al título de Ingeniero en Tecnologías de la  
Información**

**Autor:**

Samaniego Orozco, Cristian Santiago

**Tutor:**

Ph.D. Fernando Tiverio, Molina Granja.

**Riobamba, Ecuador. 2025**

## DECLARATORIA DE AUTORÍA

Yo, Cristian Santiago Samaniego Orozco, con cédula de ciudadanía 0604215012, autor del trabajo de investigación titulado: Desarrollo de una aplicación web para la evaluación de riesgo psicosocial en el ambiente laboral utilizando técnicas de machine learning, certifico que la producción, ideas, opiniones, criterios, contenidos y conclusiones expuestas son de mí exclusiva responsabilidad.

Asimismo, cedo a la Universidad Nacional de Chimborazo, en forma no exclusiva, los derechos para su uso, comunicación pública, distribución, divulgación y/o reproducción total o parcial, por medio físico o digital; en esta cesión se entiende que el cesionario no podrá obtener beneficios económicos. La posible reclamación de terceros respecto de los derechos de autor (a) de la obra referida, será de mi entera responsabilidad; librando a la Universidad Nacional de Chimborazo de posibles obligaciones.

En Riobamba, 26 de mayo de 2025.

  
Cristian Santiago Samaniego Orozco  
C.I: 0604215012



## ACTA FAVORABLE - INFORME FINAL DEL TRABAJO DE INVESTIGACIÓN

En la Ciudad de Riobamba, a los 25 días del mes de abril de 2025, luego de haber revisado el Informe Final del Trabajo de Investigación presentado por el estudiante **Cristian Santiago Samaniego Orozco** con CC: **060421501-2**, de la carrera **INGENIERÍA EN TECNOLOGÍAS DE LA INFORMACIÓN** y dando cumplimiento a los criterios metodológicos exigidos, se emite el **ACTA FAVORABLE DEL INFORME FINAL DEL TRABAJO DE INVESTIGACIÓN** titulado **“DESARROLLO DE UNA APLICACIÓN WEB PARA LA EVALUACIÓN DE RIESGO PSICOSOCIAL EN EL AMBIENTE LABORAL UTILIZANDO TÉCNICAS DE MACHINE LEARNING”**, por lo tanto se autoriza la presentación del mismo para los trámites pertinentes.



FERNANDO TIVERIO  
MOLINA GRANJA

---

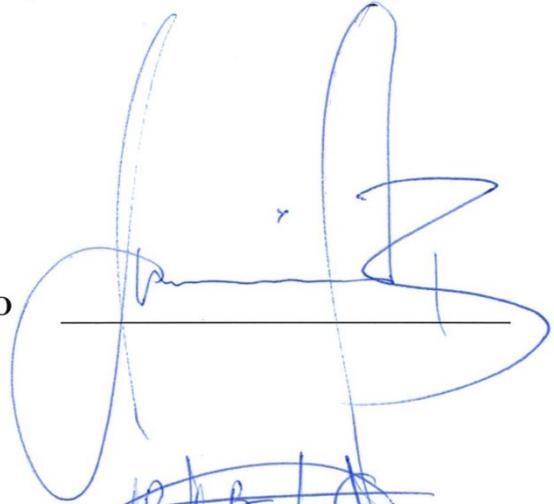
PhD. Fernando Molina Granja  
**TUTOR**

## CERTIFICADO DE LOS MIEMBROS DEL TRIBUNAL

Quienes suscribimos, catedráticos designados Miembros del Tribunal de Grado para la evaluación del trabajo de investigación, Desarrollo de una aplicación web para la evaluación de riesgo psicosocial en el ambiente laboral utilizando técnicas de machine learning, presentado por Cristian Santiago Samaniego Orozco, con cédula de identidad número 060421501-2, bajo la tutoría de Dr. Fernando Tiverio Molina Granja; certificamos que recomendamos la APROBACIÓN de este con fines de titulación. Previamente se ha evaluado el trabajo de investigación y escuchada la sustentación por parte de su autor; no teniendo más nada que observar.

De conformidad a la normativa aplicable firmamos, en Riobamba lunes, 26 de mayo de 2025.

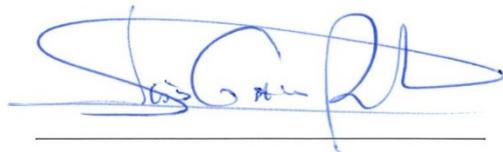
Santiago Cisneros, PhD.  
**PRESIDENTE DEL TRIBUNAL DE GRADO**

A large, stylized handwritten signature in blue ink, written over a horizontal line. The signature is highly cursive and loops around itself.

Pamela Buñay, Mgs.  
**MIEMBRO DEL TRIBUNAL DE GRADO**

A handwritten signature in blue ink, written over a horizontal line. The signature is cursive and includes the name 'Pamela Buñay'.

Gonzalo Allauca, Mgs.  
**MIEMBRO DEL TRIBUNAL DE GRADO**

A handwritten signature in blue ink, written over a horizontal line. The signature is cursive and includes the name 'Gonzalo Allauca'.



Dirección  
Académica  
VICERRECTORADO ACADÉMICO



UNACH-RGF-01-04-08.17  
VERSIÓN 01: 06-09-2021

# CERTIFICACIÓN

Que, **SAMANIEGO OROZCO CRISTIAN SANTIAGO** con CC: **0604215012**, estudiante de la Carrera de **INGENIERÍA EN TECNOLOGÍAS DE LA INFORMACIÓN**, Facultad de **INGENIERÍA**; ha trabajado bajo mi tutoría el trabajo de investigación titulado "**DESARROLLO DE UNA APLICACIÓN WEB PARA LA EVALUACIÓN DE RIESGO PSICOSOCIAL EN EL AMBIENTE LABORAL UTILIZANDO TÉCNICAS DE MACHINE LEARNING**", cumple con el **6 %**, de acuerdo al reporte del sistema Anti plagio COMPILATIO, porcentaje aceptado de acuerdo a la reglamentación institucional, por consiguiente autorizo continuar con el proceso.

Riobamba, 21 de mayo de 2025



---

PhD. Fernando Molina Granja, PD  
TUTOR

## **DEDICATORIA**

A mis padres, María Orozco y Antonio Samaniego, por su amor incondicional, por ser mi mayor ejemplo de fortaleza y dedicación, y por enseñarme que con esfuerzo y fe todo es posible. Gracias por cada sacrificio, cada palabra de aliento y por estar siempre a mi lado.

A mi familia, por su apoyo constante, su comprensión y por brindarme un hogar lleno de cariño y valores que me han guiado en cada paso. Gracias por ser mi refugio y mi motivación.

A mis amigos, quienes me acompañaron durante este proceso con paciencia, consejos, risas y mucho ánimo. Gracias por creer en mí y celebrar conmigo cada avance, por pequeño que fuera.

Este proyecto es también resultado del amor, la compañía y el respaldo de todos ustedes.

## **AGRADECIMIENTO**

Agradezco profundamente a Dios, por darme la fortaleza, la sabiduría y la salud para culminar esta etapa tan importante en mi vida.

A mis padres, María Orozco y Antonio Samaniego, por ser mi mayor fuente de inspiración, por su apoyo incondicional y por enseñarme el valor del esfuerzo y la perseverancia. Su amor ha sido fundamental en cada paso de este camino.

A mi familia, por brindarme siempre su cariño, comprensión y respaldo. Gracias por su confianza en mí y por acompañarme con su presencia constante, aún en la distancia.

A mis amigos, por su compañía, por cada palabra de aliento, por su paciencia y por estar a mi lado en los momentos más difíciles y también en los más felices. Su apoyo emocional hizo más llevadero este proceso.

A mis profesores y asesores, por compartir sus conocimientos, por su guía y compromiso. Sus enseñanzas han sido clave en mi crecimiento académico y personal.

Finalmente, gracias a todas las personas que, de una u otra forma, fueron parte de este proyecto. Cada gesto, consejo y palabra contribuyó a que hoy este trabajo sea una realidad.

## ÍNDICE GENERAL

DECLARATORIA DE AUTORÍA

DICTAMEN FAVORABLE DEL PROFESOR TUTOR

CERTIFICADO ANTIPLAGIO

DEDICATORIA

AGRADECIMIENTO

ÍNDICE GENERAL

INDICE DE TABLAS

ÍNDICE DE FIGURAS

RESUMEN

ABSTRACT

|  |    |
|--|----|
| CAPÍTULO I. INTRODUCCIÓN.....  | 14 |
| 1.1 Planteamiento del Problema.....                                  | 15 |
| 1.2 Justificación .....  | 16 |
| 1.3 Formulación del Problema .....                                   | 16 |
| 1.4 Objetivos.....   | 17 |
| CAPÍTULO II. MARCO TEÓRICO.....                                      | 18 |
| 2.1 Concepto y relevancia del Riesgo Psicosocial.....                | 18 |
| 2.2 Legislación y normativas relevantes.....                         | 18 |
| 2.3 Aplicación de Machine Learning en la evaluación de riesgos ..... | 21 |
| 2.4 Aplicaciones Web .....   | 23 |
| 2.5 Estudios y aplicaciones existentes.....                          | 24 |
| 2.6 Métricas de machine learning para evaluar modelos .....          | 26 |
| 2.7 Metodología de desarrollo ágil Kanban .....                      | 29 |
| CAPÍTULO III. METODOLOGIA .....                                      | 32 |
| 3.1 Tipo de Investigación .....                                      | 32 |
| 3.2 Diseño de la Investigación .....                                 | 32 |
| 3.3 Población de Estudio y Tamaño Muestra .....                      | 33 |
| 3.4 Técnicas de Recolección de Datos .....                           | 33 |
| 3.5 Métodos de Análisis y Procesamiento de Datos .....               | 33 |
| 3.6 Identificación de variables.....                                 | 33 |
| 3.7 Operacionalización de variables .....                            | 34 |

|  |    |
|--|----|
| 3.8 Metodología de Desarrollo.....               | 35 |
| CAPÍTULO IV. RESULTADOS Y DISCUSIÓN .....        | 52 |
| 4.1 Resultados .....                             | 52 |
| 4.2 Discusión.....                               | 55 |
| CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES ..... | 57 |
| 5.1 Conclusiones.....                            | 57 |
| 5.2 Recomendaciones.....                         | 58 |
| BIBLIOGRAFÍA .....                               | 59 |
| ANEXOS .....                                     | 62 |

## ÍNDICE DE TABLAS

|  |    |
|--|----|
| <b>Tabla 1:</b> Dimensiones del cuestionario de evaluación de riesgo psicosocial .....           | 19 |
| <b>Tabla 2:</b> Opciones de respuesta del cuestionario de evaluación de riesgo psicosocial ..... | 20 |
| <b>Tabla 3:</b> Nivel de riesgo por dimensión .....  | 20 |
| <b>Tabla 4:</b> Nivel de riesgo general.....   | 21 |
| <b>Tabla 5:</b> Ejemplo de un tablero Kanban .....   | 30 |
| <b>Tabla 6:</b> Operacionalización de variables.....   | 34 |
| <b>Tabla 7:</b> Diseño Kanban .....  | 38 |
| <b>Tabla 8:</b> Tabla auth_user .....  | 42 |
| <b>Tabla 9:</b> Tabla machilearning_respuesta .....  | 43 |

## ÍNDICE DE FIGURAS

|  |    |
|--|----|
| <b>Figura 1:</b> Aplicaciones web AWS .....                | 23 |
| <b>Figura 2:</b> Scikit-Learn algoritmo de regresión ..... | 24 |
| <b>Figura 3:</b> Definición matemática Accuracy .....      | 26 |
| <b>Figura 4:</b> Matriz de confusión estándar .....        | 27 |
| <b>Figura 5:</b> Ejemplo matriz de confusión .....         | 27 |
| <b>Figura 6:</b> Definición matemática Recall .....        | 28 |
| <b>Figura 7:</b> Curva ROC .....                           | 29 |
| <b>Figura 8:</b> Diagrama de casos de uso.....             | 40 |
| <b>Figura 9:</b> Diagrama de componentes.....              | 41 |
| <b>Figura 10:</b> Diagrama de actividades.....             | 41 |
| <b>Figura 11:</b> Esquema de base de datos.....            | 42 |
| <b>Figura 12:</b> Interfaz de inicio .....                 | 44 |
| <b>Figura 13:</b> Interfaz información .....               | 44 |
| <b>Figura 14:</b> Interfaz cuestionario .....              | 44 |
| <b>Figura 15:</b> Interfaz resultados.....                 | 44 |
| <b>Figura 16:</b> Interfaz login.....                      | 45 |
| <b>Figura 17:</b> Interfaz registro usuario.....           | 45 |
| <b>Figura 18:</b> Arquitectura cliente-servidor.....       | 45 |
| <b>Figura 19:</b> Interfaz Gráfica.....                    | 46 |
| <b>Figura 20:</b> Base de datos MySQL Workbench.....       | 46 |
| <b>Figura 21:</b> IDE Visual Studio Code .....             | 47 |
| <b>Figura 22:</b> Cálculo indicador accuracy.....          | 50 |
| <b>Figura 23:</b> Cálculo matriz de confusión .....        | 50 |
| <b>Figura 24:</b> Informe de clasificación .....           | 50 |
| <b>Figura 25:</b> Curva ROC .....                          | 51 |
| <b>Figura 26:</b> Precisión accuracy .....                 | 53 |
| <b>Figura 27:</b> Matriz de confusión .....                | 53 |
| <b>Figura 28:</b> Recall, F1-score .....                   | 54 |

## RESUMEN

La evaluación eficaz de riesgos psicosociales en el entorno laboral tradicionalmente presenta limitaciones importantes relacionadas con la precisión y la eficiencia, lo que impide una identificación temprana y efectiva de situaciones críticas para la salud ocupacional. Esta problemática es especialmente relevante debido a que los riesgos psicosociales afectan directamente la salud y el bienestar de los trabajadores, así como la productividad general de las organizaciones. Diversos esfuerzos se han realizado para mejorar la evaluación mediante métodos manuales o encuestas convencionales, los cuales resultan insuficientes debido a su subjetividad y limitada capacidad predictiva. Frente a esto, surgió la motivación de explorar tecnologías avanzadas como el machine learning, capaces de procesar grandes volúmenes de información con precisión y rapidez. Por ello, esta investigación propuso desarrollar una plataforma web que integre técnicas avanzadas de machine learning, específicamente el algoritmo SVM con kernel RBF, para clasificar automáticamente el nivel de riesgo psicosocial en los trabajadores. Los resultados obtenidos demostraron que el modelo SVM logró clasificaciones perfectas con una exactitud, recall y F1-score de 1.00, lo que evidenció su excepcional capacidad predictiva. La conclusión principal de esta investigación es que la integración del algoritmo SVM en una plataforma web intuitiva y funcional no solo mejora significativamente la precisión y la efectividad de la evaluación del riesgo psicosocial, sino que también facilita una gestión proactiva del bienestar laboral en las organizaciones.

**Palabras claves:** clasificación, Django, evaluación de riesgos, machine learning, riesgo psicosocial, SVM, tecnología web.

## ABSTRACT

Practical assessment of psychosocial risks in the workplace traditionally faces significant limitations concerning accuracy and efficiency, preventing timely and efficient identification of situations critical to occupational health. This problem is essential as psychosocial risks directly impact employee health, well-being, and organizational productivity. Numerous efforts have been made to enhance these assessments through traditional methods such as manual processes or surveys; however, these approaches are often subjective and possess limited predictive capability. Motivated by the need to improve this situation, the present research proposed the development of a web platform integrating advanced machine learning techniques, specifically a Support Vector Machine (SVM) algorithm with RBF kernel, to classify levels of psychosocial risk among employees automatically. The results demonstrated that the SVM model achieved perfect classification, with accuracy, recall, and an F1 score of 1.00, underscoring its exceptional predictive performance. The main conclusion of this research is that integrating the SVM algorithm into an intuitive and functional web platform significantly enhances the accuracy and effectiveness of psychosocial risk assessment and facilitates proactive occupational health management in organizations.

**Keywords:** classification, Django, machine learning, psychosocial risk, risk assessment, SVM, web technology.



Reviewed by:

Ms.C. Ana Maldonado León

ENGLISH PROFESSOR

C.I.0601975980

## CAPÍTULO I. INTRODUCCIÓN

En el entorno laboral contemporáneo, uno de los principales problemas radica en la insuficiente identificación y gestión efectiva de los riesgos psicosociales. Estos riesgos incluyen desde el estrés laboral crónico hasta situaciones más graves como el acoso psicológico o la violencia en el lugar de trabajo, afectando profundamente tanto la salud mental y física de los empleados como la eficiencia y productividad general de las organizaciones [1]. A pesar de su gravedad, la evaluación tradicional mediante métodos manuales como encuestas o entrevistas presenta limitaciones importantes, especialmente en cuanto a objetividad y capacidad predictiva, dificultando la detección temprana y la prevención efectiva [1].

En este contexto, diversos estudios han intentado abordar estas limitaciones, utilizando principalmente métodos tradicionales basados en cuestionarios y observación directa. Aunque útiles, estos enfoques generalmente carecen de precisión suficiente y no permiten anticiparse adecuadamente a los problemas psicosociales emergentes [2]. Además, en el contexto específico ecuatoriano y, particularmente, en instituciones educativas como la Universidad Nacional de Chimborazo (UNACH), aún existe un vacío importante en cuanto a la aplicación efectiva de tecnologías avanzadas para la evaluación de estos riesgos, lo que limita significativamente la eficacia en la gestión del bienestar laboral [2].

La importancia de esta investigación radica en la urgente necesidad de implementar métodos más precisos y eficientes que permitan identificar, evaluar y gestionar proactivamente los riesgos psicosociales en las organizaciones. Esto no solo es relevante desde una perspectiva individual, ya que protege directamente la salud y el bienestar de los trabajadores, sino también desde un enfoque organizacional, dado que permite optimizar recursos, reducir ausentismo y mejorar el clima laboral y la productividad general [3].

Ante esta problemática, varios esfuerzos recientes han comenzado a incorporar tecnologías avanzadas en la gestión de riesgos laborales. La aplicación de algoritmos de machine learning, en particular, ha demostrado resultados prometedores en diversas áreas, facilitando una evaluación más objetiva, precisa y anticipada de problemas potenciales. No obstante, aún persisten desafíos en torno a la precisión de las predicciones, la interpretación de los resultados por parte del personal no especializado y la integración efectiva de estas soluciones en los procesos cotidianos de gestión de recursos humanos [4].

Motivado por estas circunstancias, así como por la necesidad de aportar soluciones tecnológicas prácticas y eficaces para la gestión de la salud ocupacional en Ecuador, el autor emprendió esta investigación con la propuesta de desarrollar una plataforma web basada en machine learning. Concretamente, se buscó integrar algoritmos avanzados de clasificación, como el Support Vector Machine (SVM) con kernel RBF, para proporcionar una herramienta robusta y precisa que permita evaluar en tiempo real el riesgo psicosocial en los entornos laborales [4].

Finalmente, este documento se estructura en cinco capítulos claramente definidos. El Capítulo I aborda la introducción, formulación del problema y objetivos específicos de la investigación. En el Capítulo II se expone el marco teórico y conceptual relevante, incluyendo conceptos clave sobre riesgos psicosociales y técnicas de machine learning. El Capítulo III describe detalladamente la metodología empleada, la selección de la muestra, los algoritmos evaluados y las técnicas de validación. En el Capítulo IV se presentan los resultados obtenidos, así como su análisis y discusión. Por último, el Capítulo V contiene las conclusiones derivadas de los resultados y recomendaciones prácticas para futuras investigaciones o implementaciones tecnológicas relacionadas [5].

## **1.1 Planteamiento del Problema**

En el contexto laboral actual, la evaluación eficaz de los riesgos psicosociales es fundamental para garantizar un ambiente de trabajo seguro y saludable. A pesar de la importancia reconocida de gestionar estos riesgos, muchas organizaciones enfrentan dificultades para identificar y mitigar eficientemente los factores que contribuyen al estrés laboral, la insatisfacción y otros problemas psicosociales [4]. Tradicionalmente, estos riesgos se han evaluado mediante encuestas y observaciones directas, métodos que, aunque útiles, pueden ser subjetivos y no siempre ofrecen la capacidad de precisión y análisis necesaria para intervenciones tempranas y efectivas [6].

Con el avance de la tecnología de la información, en particular las técnicas de machine learning, surge la oportunidad de mejorar significativamente la evaluación de riesgos psicosociales. Estos algoritmos ofrecen la posibilidad de analizar grandes volúmenes de datos laborales, identificar patrones ocultos y predecir posibles incidencias antes de que se conviertan en problemas serios. Sin embargo, la aplicación de machine learning en este contexto aún enfrenta desafíos, especialmente en cuanto a la precisión y fiabilidad de los modelos predictivos, la interpretación de sus resultados y la integración efectiva de estos sistemas en las prácticas de gestión de recursos humanos existentes [4].

Dado este panorama, el presente estudio se propuso desarrollar y validar un modelo de machine learning que sea capaz de evaluar de manera efectiva los riesgos psicosociales en el ambiente laboral. El objetivo fue superar las limitaciones de los métodos tradicionales y ofrecer a las organizaciones una herramienta más precisa y predictiva que contribuya a la creación de estrategias de intervención más proactivas y fundamentadas. Para ello, las tecnologías utilizadas para la implementación de esta aplicación incluirán el lenguaje de alto nivel Python y diversas bibliotecas para machine learning, tales como TensorFlow, Scikit-Learn, Matplotlib y Pandas.

La base de datos que se usó fue MySQL, puesto que, esta ofrece una manipulación sencilla y se adapta eficazmente a los frameworks de despliegue. Para la integración de la aplicación web, se seleccionó el framework Django, conocido por su seguridad, desarrollo rápido, escalabilidad, y por sus funcionalidades de autenticación de usuarios y capacidades para el desarrollo web. Una vez terminado, se validó a la aplicación a diversas métricas de

desempeño de los algoritmos de machine learning, como la precisión, recall y valor F1, buscando optimizar un modelo que no solo sea robusto en términos técnicos, sino también práctico y utilizable en diversos contextos laborales.

## **1.2 Justificación**

La motivación para proponer este estudio radicó en la necesidad de validar la calidad de la clasificación de los resultados generados por la aplicación web en la evaluación del riesgo psicosocial en el entorno laboral. Al aprovechar las capacidades avanzadas del machine learning, se buscó proporcionar una herramienta más precisa y efectiva que ayude a las organizaciones a identificar y gestionar estos riesgos de manera proactiva. La intención fue contribuir al bienestar de los empleados a la eficacia organizacional mediante la implementación de tecnologías avanzadas en la gestión de recursos humanos.

El objetivo de esta investigación fue desarrollar y validar un modelo de machine learning integrado en una plataforma web diseñada para la evaluación de riesgos psicosociales. Este enfoque buscó no solo mejorar la precisión en la identificación de los riesgos, sino también proporcionar a las organizaciones una herramienta proactiva que facilite la implementación de estrategias de intervención basadas en evidencia.

Ante este contexto, el presente estudio propuso el desarrollo y la validación de un modelo de machine learning integrado en una plataforma web diseñada para la evaluación de riesgos psicosociales. A través del uso de métricas de rendimiento como la precisión, el recall y el valor F1, el estudio se enfocó en refinar la capacidad del modelo para ofrecer diagnósticos fiables y útiles en diferentes contextos laborales [7]. Además, el marco legal, incluyendo la Ley Orgánica de Seguridad y Salud en el Trabajo de Ecuador, fue considerado para garantizar la relevancia y viabilidad del proyecto. Este estudio, por lo tanto, no solo contribuyó al campo académico del machine learning y la salud ocupacional, sino que también proporciona una herramienta esencial para mejorar la salud y el bienestar en los entornos laborales modernos [8].

## **1.3 Formulación del Problema**

¿Cómo incide el desarrollo de una aplicación web que utiliza técnicas de machine learning en la calidad de la clasificación de los resultados al evaluar el riesgo psicosocial en el ambiente laboral?

## **1.4 Objetivos**

### **Objetivo General**

Desarrollar una plataforma web que permita evaluar los riesgos psicosociales en el entorno laboral utilizando técnicas de machine learning.

### **Objetivos Específicos**

- Analizar algoritmos de machine learning adecuados para la creación de un aplicativo para la evaluación de riesgos psicosociales.
- Implementar la plataforma web integrando técnicas de machine learning para la evaluación de riesgo psicosocial en el ambiente laboral.
- Validar la calidad de la clasificación de los resultados generados por la aplicación web en la evaluación del riesgo psicosocial en el entorno laboral, mediante el análisis de métricas de rendimiento del modelo.

## **CAPÍTULO II. MARCO TEÓRICO**

### **2.1 Concepto y relevancia del Riesgo Psicosocial**

El término "riesgo psicosocial" se refiere a aquellos aspectos relacionados con la organización, el contenido del trabajo y la realización de las tareas que tienen la potencialidad de causar daños físicos, sociales o psicológicos a los trabajadores. Según la Organización Mundial de la Salud, estos riesgos derivan de malas prácticas de diseño, organización y gestión, así como de un contexto social negativo en el trabajo [9]. Identificar y mitigar estos riesgos es crucial para promover un ambiente laboral saludable y productivo.

Específicamente, los riesgos psicosociales incluyen factores como el exceso de carga de trabajo, la falta de claridad en las responsabilidades laborales, la presión constante para alcanzar metas, y la falta de apoyo social por parte de compañeros y superiores. Estos elementos pueden generar estrés, ansiedad y otros problemas de salud mental, afectando negativamente el rendimiento y bienestar de los empleados.

Estudios han demostrado que una gestión adecuada de los riesgos psicosociales no solo mejora la salud mental y física de los trabajadores, sino que también incrementa la eficiencia y productividad de las organizaciones. Implementar políticas de trabajo flexibles, fomentar una comunicación abierta y proporcionar recursos para el manejo del estrés son algunas de las estrategias efectivas para abordar estos riesgos.

### **2.2 Legislación y normativas relevantes**

En el ámbito legal, diversas regulaciones internacionales y nacionales establecen directrices para la evaluación y manejo de los riesgos psicosociales. La "Ley Orgánica de Prevención de Riesgos Laborales" (2015), por ejemplo, obliga a los empleadores a garantizar la seguridad y salud de sus empleados en todos los aspectos relacionados con el trabajo [10]. Estas normativas son esenciales para enmarcar la responsabilidad organizacional y promover prácticas de trabajo seguras.

Ecuador cuenta con un marco regulatorio detallado destinado a garantizar la seguridad y salud en el trabajo, incluyendo la prevención de riesgos psicosociales. Este marco se encuentra principalmente en la Ley Orgánica de Prevención, Detección y Erradicación del Trabajo Infantil y Protección del Adolescente Trabajador y su respectivo reglamento, así como en el Acuerdo Ministerial No. 140 emitido por el Ministerio de Relaciones Laborales [11].

Promover un entorno laboral inclusivo y comprensivo, donde los empleados se sientan valorados y escuchados, resulta esencial para reducir los riesgos psicosociales. Además, la formación y sensibilización sobre la importancia del bienestar psicosocial en el trabajo son fundamentales para crear una cultura organizacional positiva.

### 2.2.1 Ley Orgánica de Seguridad y Salud en el Trabajo (LOSST)

La Ley Orgánica de Seguridad y Salud en el Trabajo, promulgada en 2015, es la principal ley que regula la seguridad y salud en el ámbito laboral en Ecuador. Esta ley establece las obligaciones y derechos tanto de empleadores como de trabajadores para garantizar un ambiente de trabajo seguro y saludable. Específicamente, se refiere a la identificación, evaluación, prevención y control de los riesgos laborales, incluidos los psicosociales, destacando la importancia de implementar medidas preventivas y correctivas adecuadas [12].

Además, la ley enfatiza la necesidad de una formación continua y adecuada para los trabajadores en materia de seguridad y salud ocupacional. Los empleadores están obligados a proporcionar esta formación para asegurar que los empleados estén informados sobre los riesgos a los que pueden estar expuestos y las medidas que deben tomar para protegerse.

La normativa también impulsa la creación de comités de seguridad y salud en el trabajo, formados por representantes de los trabajadores y empleadores. Estos comités son responsables de supervisar y coordinar las actividades relacionadas con la seguridad y salud laboral, así como de promover la implementación de buenas prácticas en el lugar de trabajo.

### 2.2.2 Cuestionario de evaluación de riesgo psicosocial

El cuestionario de evaluación de riesgo psicosocial está dirigido a personas naturales y jurídicas, empresas públicas y privadas, instituciones e instancias públicas con más de 10 trabajadores y/o servidores. El cuestionario propuesto por el Ministerio del Trabajo no es de aplicación obligatoria para la evaluación del riesgo psicosocial, la empresa o institución puede seleccionar otro instrumento de evaluación que cuente con los estudios de validez y fiabilidad nacional o internacional [13]. En muchos casos, estos cuestionarios incluyen preguntas sobre la carga de trabajo, el nivel de estrés percibido, la calidad de las relaciones interpersonales en el trabajo, y la claridad de las tareas y responsabilidades. Estas evaluaciones permiten a las organizaciones identificar áreas problemáticas y desarrollar planes de acción para mitigar los riesgos identificados, mejorando así el bienestar general de los empleados. En la Tabla 1 a continuación se puede observar la estructura general del cuestionario.

**Tabla 1:** Dimensiones del cuestionario de evaluación de riesgo psicosocial

| Dimensión                                       | Número total de ítems | Número de ítem en el cuestionario |
|---|-----------------------|-----------------------------------|
| Carga y ritmo de trabajo                        | 4                     | 1, 2, 3, 4                        |
| Desarrollo de competencias                      | 4                     | 5, 6, 7, 8                        |
| Liderazgo                                       | 6                     | 9, 10, 11, 12, 13, 14             |
| Margen de acción y control                      | 4                     | 15, 16, 17, 18                    |
| Organización del trabajo                        | 6                     | 19, 20, 21, 22, 23, 24            |
| Recuperación                                    | 5                     | 25, 26, 27, 28, 29                |
| Soporte y apoyo                                 | 5                     | 30, 31, 32, 33, 34                |
| Otros puntos importantes                        | 24                    | 35 al 58                          |
| Otros puntos importantes: Acoso discriminatorio | 4                     | 35, 38, 53, 56                    |

|  |   |                    |
|--|---|--------------------|
| Otros puntos importantes: Acoso laboral                        | 2 | 41, 50             |
| Otros puntos importantes: Acoso sexual                         | 2 | 43, 48             |
| Otros puntos importantes: Adicción al trabajo                  | 5 | 36, 45, 51, 55, 57 |
| Otros puntos importantes: Condiciones del Trabajo              | 2 | 40, 47             |
| Otros puntos importantes: Doble presencia (laboral – familiar) | 2 | 46, 49             |
| Otros puntos importantes: Estabilidad laboral y emocional      | 5 | 37, 39, 42, 52, 54 |
| Otros puntos importantes: Salud auto percibida                 | 2 | 44, 58             |

Fuente: [14]

En Ecuador, con el fin de proporcionar una herramienta que promueva el cumplimiento del programa de prevención de riesgo psicosocial se desarrolló una propuesta de cuestionario de evaluación de riesgo psicosocial. El cuestionario permite evaluar factores de riesgo psicosocial es decir situaciones que pueden producir daño a la salud del trabajador/servidor proporcionando un diagnóstico inicial desde el punto de vista psicosocial y constituye un punto de partida para evaluaciones más específicas en aquellas áreas que presenten deficiencias [15]. En la Tabla 2 a continuación podemos observar una escala de Likert, esta empieza desde parcialmente de acuerdo poco de acuerdo y desacuerdo según corresponda.

**Tabla 2:** Opciones de respuesta del cuestionario de evaluación de riesgo psicosocial

| Opción de respuesta      | Puntuación |
|--------------------------|------------|
| Completamente de Acuerdo | 4          |
| Parcialmente de Acuerdo  | 3          |
| Poco de Acuerdo          | 2          |
| En desacuerdo            | 1          |

Fuente: [14]

Este recurso también permite a los empleadores comprender mejor las necesidades y preocupaciones de sus trabajadores, fomentando un ambiente laboral más saludable y productivo. Asimismo, puede servir como una herramienta de seguimiento constante para garantizar que las intervenciones aplicadas estén logrando el impacto esperado en la disminución de los riesgos psicosociales. Para evaluar el nivel de riesgo por dimensión, se realizará una suma de las puntuaciones obtenidas de los ítems que componen cada dimensión, y el resultado se confrontará con los valores establecidos en la Tabla 3 a continuación detallada.

**Tabla 3:** Nivel de riesgo por dimensión

| Dimensión                                       | Riesgo Bajo | Riesgo Medio | Riesgo Alto |
|---|-------------|--------------|-------------|
| Carga y ritmo de trabajo                        | 13 a 16     | 8 a 12       | 4 a 7       |
| Desarrollo de competencias                      | 13 a 16     | 8 a 12       | 4 a 7       |
| Liderazgo                                       | 18 a 24     | 12 a 17      | 6 a 11      |
| Margen de acción y control                      | 13 a 16     | 8 a 12       | 4 a 7       |
| Organización del trabajo                        | 18 a 24     | 12 a 17      | 6 a 11      |
| Recuperación                                    | 16 a 20     | 10 a 15      | 5 a 9       |
| Soporte y apoyo                                 | 16 a 20     | 10 a 15      | 5 a 9       |
| Otros puntos importantes                        | 73 a 96     | 49 a 72      | 24 a 48     |
| Otros puntos importantes: Acoso discriminatorio | 13 a 16     | 8 a 12       | 4 a 7       |

|  |         |         |       |
|--|---------|---------|-------|
| Otros puntos importantes: Acoso laboral                        | 7 a 8   | 5 a 6   | 2 a 4 |
| Otros puntos importantes: Acoso sexual                         | 7 a 8   | 5 a 6   | 2 a 4 |
| Otros puntos importantes: Adicción al trabajo                  | 16 a 20 | 10 a 15 | 5 a 9 |
| Otros puntos importantes: Condiciones del Trabajo              | 7 a 8   | 5 a 6   | 2 a 4 |
| Otros puntos importantes: Doble presencia (laboral – familiar) | 7 a 8   | 5 a 6   | 2 a 4 |
| Otros puntos importantes: Estabilidad laboral y emocional      | 16 a 20 | 10 a 15 | 5 a 9 |
| Otros puntos importantes: Salud auto percibida                 | 7 a 8   | 5 a 6   | 2 a 4 |

Fuente: [14]

Por último, para determinar el nivel de riesgo general se calculará sumando las puntuaciones de cada dimensión, y el resultado obtenido se comparará con los valores indicados en la siguiente Tabla 4.

**Tabla 4:** Nivel de riesgo general

| Nivel de Riesgo | Calificación | Descripción   |
|-----------------|--------------|---|
| Alto            | 58 a 116     | El riesgo es de impacto potencial alto sobre la seguridad y la salud de las personas, los niveles de peligro son intolerables y pueden generar efectos nocivos para la salud e integridad física de las personas de manera inmediata. Se deben aplicar las medidas de seguridad y prevención de manera continua y conforme a la necesidad específica identificada para evitar el incremento a la probabilidad y frecuencia.                                       |
| Medio           | 117 a 174    | El riesgo es de impacto potencial moderado sobre la seguridad y salud. Puede comprometer las mismas en el mediano plazo, causando efectos nocivos para la salud, afectaciones a la integridad física y enfermedades ocupacionales. En caso de que no se aplicaren las medidas de seguridad y prevención correspondientes de manera continua y conforme a la necesidad específica identificada, los impactos pueden generarse con mayor probabilidad y frecuencia. |
| Bajo            | 175 a 232    | El riesgo es de impacto potencial mínimo sobre la seguridad y salud, no genera a corto plazo efectos nocivos. Estos efectos pueden ser evitados a través de un monitoreo periódico de la frecuencia y probabilidad de que ocurra y se presente una enfermedad ocupacional. Las acciones irán enfocadas a garantizar que el nivel se mantenga.   |

Fuente: [14]

### 2.3 Aplicación de Machine Learning en la evaluación de riesgos

El machine learning ofrece métodos avanzados para el análisis y la predicción de riesgos psicosociales, mediante el uso de grandes volúmenes de datos y modelos predictivos. Alpaydin (2020) describe cómo los algoritmos pueden aprender de los datos y ayudar a prever condiciones de trabajo que podrían ser perjudiciales, permitiendo intervenciones

tempranas y más efectivas [16]. Esto permite a las organizaciones reconocer patrones y tendencias en los datos que podrían no ser evidentes con enfoques tradicionales, proporcionando una capa adicional de análisis que mejora notablemente la capacidad de reacción ante posibles riesgos.

### **2.3.1 Identificación de factores de riesgo**

El primer paso en la aplicación de ML es la identificación de factores de riesgo a través del análisis de datos. Algoritmos de clasificación y regresión pueden analizar grandes conjuntos de datos laborales, como encuestas de satisfacción, registros de salud, y datos de sensores de comportamiento o ambientales, para identificar correlaciones y patrones asociados con el bienestar de los trabajadores. Por ejemplo, un modelo de regresión logística puede ser usado para predecir la probabilidad de que un empleado experimente estrés basado en variables como carga de trabajo, horas de trabajo, y dinámicas de equipo [17].

Estos modelos de machine learning no solo facilitan la identificación de factores de riesgo, sino que también ofrecen una visión detallada de cómo estos factores se relacionan entre sí. Al reconocer las interacciones complejas entre las variables, se pueden crear estrategias más específicas y efectivas para reducir los riesgos. Por ejemplo, al comprender cómo la ausencia de apoyo social puede intensificar los efectos negativos de una carga laboral alta, se pueden implementar medidas de apoyo y bienestar que aborden ambos aspectos al mismo tiempo.

### **2.3.2 Predicción de riesgos y alertas tempranas**

Una vez identificados los factores de riesgo, los modelos predictivos de ML se utilizan para prever posibles incidencias de riesgos psicosociales antes de que se manifiesten. Algoritmos como las redes neuronales y las máquinas de soporte vectorial (SVM) son capaces de procesar y aprender de datos históricos y en tiempo real, proporcionando predicciones precisas que permiten intervenciones tempranas. Esto es particularmente útil en entornos laborales dinámicos donde los factores de riesgo pueden cambiar rápidamente [18].

La habilidad de estos modelos para ajustarse y actualizarse con datos nuevos les permite permanecer relevantes y efectivos, garantizando que las estrategias de intervención sigan siendo pertinentes y oportunas. La adopción de estos sistemas no solo contribuye a la prevención de problemas de salud, sino que también optimiza el uso de los recursos organizacionales, al permitir que las intervenciones se enfoquen en los puntos más críticos. Así, se promueve un entorno laboral más seguro y saludable, disminuyendo la incidencia de trastornos relacionados con el estrés y mejorando el bienestar general de los empleados.

### **2.3.3 Monitoreo continuo y evaluaciones dinámicas**

El ML facilita el monitoreo continuo del ambiente laboral mediante el uso de modelos que se actualizan constantemente con nuevos datos. Esto permite que las

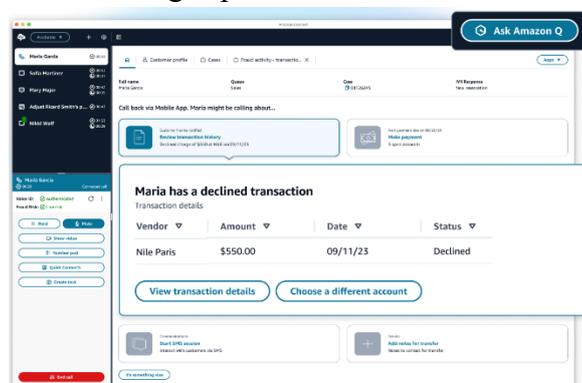
evaluaciones de riesgo sean dinámicas y reflejen las condiciones actuales del lugar de trabajo. Por ejemplo, el uso de modelos de aprendizaje profundo (deep learning) para analizar la comunicación en el lugar de trabajo puede ayudar a detectar cambios en el sentimiento del personal que podrían indicar problemas emergentes como el acoso o el deterioro de las relaciones entre colegas [19].

El desarrollo de aplicaciones web efectivas para la evaluación de riesgos psicosociales requiere un enfoque integral que combine tecnología y diseño centrado en el usuario. Freeman y Robson (2004) resaltan la importancia de adoptar patrones de diseño que mejoren la interactividad y accesibilidad, asegurando que los usuarios puedan utilizar la aplicación de manera eficiente y sin dificultades [20].

La integración de machine learning en una aplicación web implica varios desafíos técnicos, incluyendo la selección de algoritmos apropiados, el entrenamiento de modelos con grandes volúmenes de datos y la implementación de estos modelos de manera que puedan procesar consultas en tiempo real. Las bibliotecas y frameworks como TensorFlow, Scikit-learn y PyTorch son herramientas comunes que facilitan la integración de capacidades de ML en aplicaciones web. Además, es vital asegurar que los modelos de ML se mantengan actualizados y sean capaces de adaptarse a nuevos datos y patrones emergentes [21].

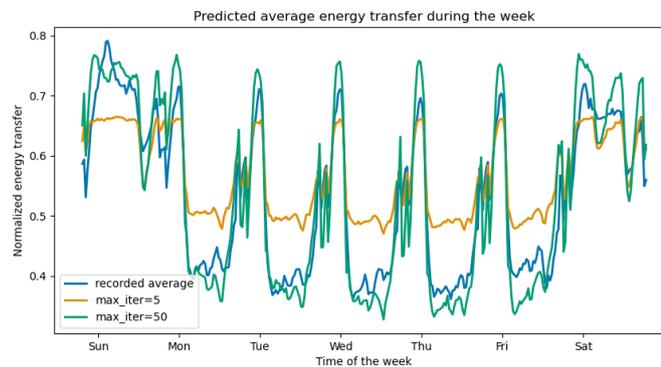
## 2.4 Aplicaciones Web

El desarrollo de aplicaciones web efectivas para la evaluación de riesgos psicosociales requiere un enfoque integral que combine tecnología y diseño centrado en el usuario. Freeman y Robson (2004) resaltan la importancia de adoptar patrones de diseño que mejoren la interactividad y accesibilidad, asegurando que los usuarios puedan utilizar la aplicación de manera eficiente y sin dificultades [20]. El diseño debe tener en cuenta la simplicidad y la claridad en la presentación de los datos, lo que facilita a los usuarios interpretar los resultados y tomar decisiones informadas. La experiencia del usuario (UX) es fundamental para la aceptación y el uso continuo de la aplicación, lo que, a su vez, impacta en la efectividad de la evaluación de riesgos psicosociales.



**Figura 1:** Aplicaciones web AWS  
**Fuente:** [22]

La integración de machine learning en una aplicación web implica varios desafíos técnicos, incluyendo la selección de algoritmos apropiados, el entrenamiento de modelos con grandes volúmenes de datos y la implementación de estos modelos de manera que puedan procesar consultas en tiempo real. Las bibliotecas y frameworks como TensorFlow, Scikit-learn y PyTorch son herramientas comunes que facilitan la integración de capacidades de ML en aplicaciones web. Además, es vital asegurar que los modelos de ML se mantengan actualizados y sean capaces de adaptarse a nuevos datos y patrones emergentes [21]. La actualización y el entrenamiento constantes de los modelos aseguran que las predicciones y evaluaciones se mantengan precisas y pertinentes, la aplicación de estrategias de validación y pruebas exhaustivas es crucial para preservar la confiabilidad y solidez de los modelos en entornos de producción.



**Figura 2:** Scikit-Learn algoritmo de regresión  
**Fuente:** [23]

## 2.5 Estudios y aplicaciones existentes

En la literatura reciente, se evidencia un creciente interés en la aplicación de técnicas de machine learning para evaluar y gestionar los riesgos psicosociales en el ambiente laboral. Esta sección profundiza en estudios clave y explora cómo estas tecnologías están siendo utilizadas para desarrollar soluciones innovadoras que mejoran la seguridad y bienestar en el trabajo.

### 2.5.1 Análisis predictivo para la evaluación del estrés

Un ejemplo significativo es el estudio realizado por Smith y Doe (2018), donde desarrollaron un modelo predictivo utilizando algoritmos de aprendizaje automático para identificar factores de estrés en empleados del sector financiero. Este estudio utilizó técnicas de análisis de regresión y clasificación para analizar datos recopilados a través de cuestionarios y sensores de actividad física. Los resultados mostraron una alta precisión en la predicción de episodios de estrés, lo que demuestra la eficacia del machine learning para proporcionar alertas tempranas y posibilitar intervenciones proactivas [24].

El estudio subrayó la relevancia de combinar datos de diversas fuentes para lograr una comprensión más integral del bienestar de los empleados. Los autores también propusieron que estos modelos pudieran implementarse en otras industrias para ampliar la gestión de riesgos psicosociales. La capacidad de estos modelos para

adaptarse y aprender de datos nuevos y en evolución los convierte en herramientas valiosas para la gestión continua del estrés y el bienestar laboral.

### **2.5.2 Sistemas de monitorización en tiempo real**

Otro avance importante es el desarrollo de sistemas de monitorización en tiempo real que utilizan datos de comportamiento y biométricos. En 2017, García et al. diseñaron un sistema que integraba machine learning con dispositivos wearables para monitorizar la frecuencia cardíaca y los patrones de sueño de los trabajadores en industrias de alta demanda. Los algoritmos de clasificación, como las Máquinas de Soporte Vectorial (SVM), fueron empleados para detectar anomalías que indicaran niveles elevados de estrés o fatiga. Este tipo de sistemas no solo ayuda en la evaluación continua de la salud de los empleados, sino que también promueve un ambiente laboral más seguro [25].

La integración de estos sistemas con plataformas de gestión de salud ocupacional permite a los gerentes a tomar decisiones fundamentadas en datos precisos y actualizados en tiempo real. Además, la capacidad de estos dispositivos para ofrecer retroalimentación inmediata a los empleados sobre su estado de salud promueve hábitos saludables y una mayor conciencia sobre el autocuidado. Este enfoque proactivo no solo mejora el bienestar de los trabajadores, sino que también puede disminuir considerablemente los costos relacionados con la atención médica y las ausencias laborales, creando un entorno de trabajo más eficiente y equilibrado.

### **2.5.3 Modelos de aprendizaje profundo para el análisis del sentimiento**

La investigación de Chen et al. (2019) exploró el uso de modelos de aprendizaje profundo para el análisis del sentimiento en comunicaciones escritas en el lugar de trabajo, como correos electrónicos y mensajes de chat. Utilizando redes neuronales convolucionales (CNN) y procesamiento de lenguaje natural (NLP), el estudio identificó patrones de comunicación que podrían indicar insatisfacción laboral o conflictos interpersonales. Estos hallazgos son fundamentales para desarrollar intervenciones dirigidas a mejorar la comunicación y el clima organizacional [26].

La habilidad de estas tecnologías para procesar grandes cantidades de datos en tiempo real permite a las organizaciones enfrentar problemas de manera más ágil y eficaz. Este enfoque no solo optimiza la identificación de posibles inconvenientes, sino que también facilita una retroalimentación constante y constructiva, fomentando un ambiente laboral más colaborativo y saludable.

### **2.5.4 Evaluación comparativa de herramientas de Machine Learning**

Finalmente, un estudio realizado por Wilson y colaboradores (2020) proporcionó una evaluación comparativa de diferentes herramientas y técnicas de machine learning en el contexto de la salud laboral. Este estudio evaluó la eficacia de diversos modelos, incluidos árboles de decisión, bosques aleatorios y redes neuronales, en la predicción de enfermedades relacionadas con el trabajo y accidentes. Los resultados ayudaron a

identificar las herramientas más efectivas y eficientes para su implementación en sistemas de gestión de riesgos psicosociales [27]. la investigación subrayó la relevancia de la precisión y la interpretabilidad de los modelos, sugiriendo que una combinación de diferentes algoritmos puede proporcionar una solución más efectiva para la predicción y mitigación de riesgos.

## 2.6 Métricas de machine learning para evaluar modelos

En machine learning, es fundamental evaluar correctamente el modelo para garantizar que las predicciones describan con precisión el fenómeno deseado. Existen muchas métricas de rendimiento diferentes (precisión, recall, puntaje F1, etc.), y seleccionar la métrica adecuada para un modelo específico es clave para medir objetivamente el rendimiento del modelo en el contexto adecuado [28].

La precisión puede ser útil en conjuntos de datos equilibrados, pero en situaciones con clases desbalanceadas, métricas como el recall y el puntaje F1 son más apropiadas, ya que ofrecen una visión más completa de la capacidad del modelo para identificar correctamente las instancias positivas y minimizar los falsos negativos. Además, el uso de curvas ROC y áreas bajo la curva (AUC) permite evaluar el rendimiento del modelo a través de diferentes umbrales de decisión, proporcionando una herramienta más sólida para comparar modelos en diversas condiciones operativas. La elección adecuada de métricas no solo mejora la interpretación de los resultados, sino que también orienta la optimización y ajuste de los modelos para cumplir con los objetivos específicos del análisis.

### 2.6.1 Precisión (Accuracy)

La precisión es la fracción de predicciones que nuestro modelo acertó de todas las predicciones realizadas. Esto significa que sumamos el número de predicciones correctamente predichas como positivas (TP) o correctamente predichas como negativas (TN) y lo dividimos por todos los tipos de predicciones, tanto correctas (TP, TN) como incorrectas (FP, FN) [28].

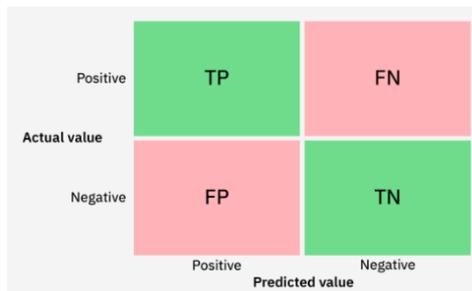
$$\text{Accuracy} = \frac{\text{correct classifications}}{\text{total classifications}} = \frac{TP + TN}{TP + TN + FP + FN}$$

**Figura 3:** Definición matemática Accuracy

**Fuente:** [29]

### 2.6.2 Matriz de confusión

La matriz de confusión proporciona una visión detallada del rendimiento del modelo al mostrar verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos. Es una tabla que organiza estos cuatro valores para evaluar el rendimiento del modelo [28]. Cada celda de la matriz permite no solo entender cuántas predicciones fueron correctas, sino también la naturaleza de los errores cometidos.



**Figura 4:** Matriz de confusión estándar

Fuente: [30]

Esto facilita la identificación de si el modelo está confundiendo una clase con otra, lo cual es fundamental para aumentar su precisión. Por ejemplo, en un diagnóstico médico, la matriz de confusión puede mostrar si el modelo presenta una alta tasa de falsos negativos, lo que sería crítico para la salud del paciente, las métricas derivadas de esta matriz, como la precisión, el recall y la especificidad, ofrecen una evaluación más completa del rendimiento del modelo. Estas métricas permiten ajustar y optimizar los algoritmos para mejorar su fiabilidad y robustez en situaciones del mundo real. Utilizar la matriz de confusión como herramienta de análisis ayuda a tomar decisiones informadas sobre las modificaciones necesarias para perfeccionar el modelo. A continuación, en la figura 4, presenta una fracción de código para calcular dicha matriz.

```
>>> from sklearn.metrics import confusion_matrix
>>> y_true = [2, 0, 2, 2, 0, 1]
>>> y_pred = [0, 0, 2, 2, 0, 2]
>>> confusion_matrix(y_true, y_pred)
array([[2, 0, 0],
       [0, 0, 1],
       [1, 0, 2]])

>>> y_true = ["cat", "ant", "cat", "cat", "ant", "bird"]
>>> y_pred = ["ant", "ant", "cat", "cat", "ant", "cat"]
>>> confusion_matrix(y_true, y_pred, labels=["ant", "bird", "cat"])
array([[2, 0, 0],
       [0, 0, 1],
       [1, 0, 2]])
```

**Figura 5:** Ejemplo matriz de confusión

Fuente: [23]

### 2.6.3 Recall

El recall mide la capacidad del modelo para identificar correctamente todas las instancias positivas. Se calcula dividiendo las muestras correctamente predichas como positivas (TP) por el número total de positivos, ya sea correctamente predichos como positivos o incorrectamente predichos como negativos (TP, FN) [28]. Esta métrica es especialmente relevante en contextos donde es vital detectar todas las instancias positivas, como en diagnósticos médicos, donde omitir un caso positivo puede tener serias repercusiones para la salud del paciente.

El recall, también conocido como sensibilidad, mide la capacidad del modelo para identificar todas las instancias relevantes dentro de un conjunto de datos, y es esencial para evaluar el rendimiento de los modelos en tareas de clasificación binaria. Junto

con otras métricas, como la precisión y el puntaje F1, el recall proporciona una visión más integral del rendimiento del modelo y facilita la toma de decisiones informadas sobre cómo ajustar y mejorar los algoritmos para lograr mejores resultados en aplicaciones prácticas.

$$\text{Recall (or TPR)} = \frac{\text{correctly classified actual positives}}{\text{all actual positives}} = \frac{TP}{TP + FN}$$

**Figura 6:** Definición matemática Recall  
**Fuente:** [29]

#### 2.6.4 Puntaje F1 (F1 Score)

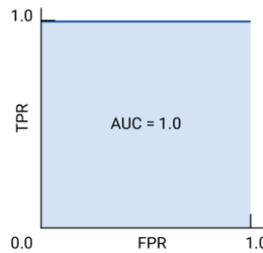
El puntaje F1 es la media armónica de la precisión y el recall, proporcionando una métrica equilibrada que considera tanto los falsos positivos como los falsos negativos. El valor más alto de un puntaje F1 es 1, indicando precisión y recall perfectos, y el valor más bajo posible es 0 si la precisión o el recall es cero [28]. Esta métrica es particularmente útil en situaciones donde hay un desbalance de clases, es decir, cuando una clase es significativamente más frecuente que la otra. En estos casos, el puntaje F1 proporciona una evaluación más precisa del rendimiento del modelo en comparación con la simple precisión, que podría resultar engañosa.

El puntaje F1 es esencial para tareas como la detección de fraudes, diagnósticos médicos y otros contextos en los que tanto los falsos positivos como los falsos negativos pueden tener consecuencias importantes. Al combinar la precisión y el recall, el puntaje F1 ayuda a equilibrar la necesidad de identificar correctamente los verdaderos positivos mientras se minimizan los errores.

Esta métrica de evaluación permite a los desarrolladores de modelos ajustar sus algoritmos de manera más efectiva, centrándose en optimizar tanto la precisión como la sensibilidad del modelo. Esto, a su vez, contribuye a la creación de modelos más robustos y confiables para aplicaciones prácticas.

#### 2.6.5 Curva ROC

La curva ROC es un gráfico que muestra el rendimiento de un modelo de clasificación en todos los umbrales de clasificación. El eje y del gráfico es la tasa de verdaderos positivos, mientras que el eje x es la tasa de falsos positivos. La AUC (Área Bajo la Curva) mide el área bidimensional debajo de toda la curva ROC [28]. Esta métrica es fundamental para evaluar la capacidad del modelo para diferenciar entre clases positivas y negativas a través de diferentes umbrales. Un modelo ideal mostrará una curva ROC que se acerque a la esquina superior izquierda del gráfico, lo que indica una alta tasa de verdaderos positivos y una baja tasa de falsos positivos.



**Figura 7:** Curva ROC  
**Fuente:** [29]

La AUC ofrece una única métrica que resume el rendimiento total del modelo, siendo útil para comparar distintos modelos. Cuanto más cercana esté la AUC a 1, mejor será el rendimiento del modelo. Esta capacidad de evaluar el rendimiento general en lugar de centrarse en un único umbral específico convierte a la curva ROC y la AUC en herramientas valiosas para la optimización y selección de modelos de clasificación, especialmente en situaciones donde es necesario gestionar cuidadosamente el equilibrio entre falsos positivos y falsos negativos. Incluir estas métricas en la evaluación de modelos garantiza que se tomen decisiones informadas y fundamentadas en datos precisos sobre su implementación y ajustes necesarios.

## 2.7 Metodología de desarrollo ágil Kanban

Kanban es una metodología ágil diseñada para gestionar la producción de trabajo con énfasis en la eficiencia just-in-time y una respuesta flexible a los cambios de demanda. Originada en los sistemas de producción de Toyota en la década de 1940, Kanban ha evolucionado hasta convertirse en una de las metodologías ágiles más populares utilizadas en el desarrollo de software, gestión de proyectos, y otras áreas que requieren adaptabilidad y continua entrega de valor [31]. La metodología se fundamenta en la visualización del flujo de trabajo, la limitación del trabajo en curso y la mejora continua del proceso a través de la identificación y eliminación de cuellos de botella. Este enfoque visual y organizado permite a los equipos gestionar las tareas de manera más eficiente, priorizar trabajos críticos y aumentar la eficiencia general, a su vez, fomenta una cultura de mejora continua y adaptabilidad, lo cual es fundamental en entornos dinámicos y en constante cambio.

Kanban se basa en cuatro principios fundamentales que guían su implementación y práctica:

- **Visualizar el trabajo:** Utilizar un tablero Kanban para visualizar todas las tareas del proyecto en diferentes etapas de desarrollo (por hacer, en progreso, y completado). Esto proporciona una visibilidad clara del flujo de trabajo y ayuda a identificar cuellos de botella o retrasos en el proceso. Al tener una representación visual del progreso, los equipos pueden colaborar de manera más efectiva y ajustar prioridades según sea necesario. Además, facilita la comunicación entre los miembros del equipo, asegurando que todos estén alineados con los objetivos del proyecto. A continuación, la Tabla 5, ofrece una visualización clara del flujo de trabajo. Las tareas se distribuyen en diferentes columnas según su estado actual.

**Tabla 5:** Ejemplo de un tablero Kanban

| Por hacer               | En progreso                  | En revisión                         | Completado         |
|-------------------------|------------------------------|-------------------------------------|--------------------|
| Diseñar el logo         | Redactar contenido de la web | Revisar el diseño del logo          | Configurar hosting |
| Crear paleta de colores | Crear maquetas iniciales     | Probar funcionalidad de formularios | Publicar sitio web |
| Recopilar información   |                              |                                     |                    |

- **Limitar el trabajo en progreso (WIP):** Imponer límites en la cantidad de tareas en las diferentes etapas del proceso para evitar la sobrecarga miento del equipo y garantizar un flujo de trabajo continuo y gestionable. Esto garantiza que cada miembro del equipo pueda concentrarse en sus tareas sin sentirse sobrecargado, lo que mejora la calidad del trabajo y disminuye el estrés. Además, facilita la identificación rápida de cuellos de botella y la redistribución de recursos para mantener la eficiencia y productividad en el proyecto.
- **Gestionar el flujo:** Observar y gestionar el movimiento de tareas a través del tablero Kanban para asegurar una entrega continua. Esto implica ajustar los límites de WIP o redistribuir recursos según sea necesario para mejorar la eficiencia. De esta manera permite identificar rápidamente cualquier bloqueo que pueda surgir y abordarlo antes de que afecte el progreso del proyecto. Mantener una revisión constante del flujo de trabajo también fomenta la mejora continua, asegurando que el equipo pueda adaptarse a cambios imprevistos y seguir avanzando hacia sus objetivos.
- **Mejora continua:** Fomentar un ciclo constante de evaluación y ajuste del proceso de trabajo para mejorar la eficacia y la eficiencia del equipo [32]. Esto implica realizar revisiones periódicas de los flujos de trabajo y las prácticas actuales para detectar oportunidades de mejora. También abarca la integración de la retroalimentación del equipo para realizar ajustes necesarios en tiempo real, es fundamental implementar estrategias de aprendizaje continuo y capacitación para mantener al equipo al día con las mejores prácticas y las herramientas más recientes.

Los beneficios de implementar Kanban incluyen:

- **Flexibilidad:** Kanban permite un alto grado de adaptabilidad en respuesta a cambios en las prioridades del proyecto o en las demandas del cliente. Este enfoque flexible permite a los equipos reorganizar su trabajo rápidamente para adaptarse a nuevas circunstancias, asegurando que se mantengan alineados con los objetivos del proyecto. La capacidad de ajustar y redistribuir tareas según las necesidades emergentes es crucial para mantener la eficiencia y la productividad en un entorno laboral dinámico. La visualización continua de las tareas facilita la identificación de problemas y la implementación inmediata de soluciones.

- **Eficiencia mejorada:** Al limitar el trabajo en progreso y visualizar el flujo de trabajo, Kanban ayuda a identificar y resolver rápidamente los cuellos de botella, lo que resulta en un proceso más eficiente. Esta metodología permite a los equipos mantener un enfoque constante en tareas específicas sin distracciones, lo que resulta en una ejecución más ágil y precisa. La transparencia de esta metodología facilita la coordinación y colaboración entre los miembros del equipo, lo que incrementa la cohesión y el rendimiento colectivo.

## **CAPÍTULO III. METODOLOGIA**

El objetivo principal de este proyecto de investigación es analizar los riesgos psicosociales en el entorno laboral a través de la aplicación de algoritmos de machine learning. La creciente relevancia de la salud y el bienestar en el trabajo ha generado la necesidad de crear herramientas efectivas que faciliten la identificación y gestión precisa y confiable de los factores de riesgo psicosocial. Este estudio adopta un enfoque cuantitativo, enfocándose en la implementación y validación de algoritmos que se integrarán en una plataforma web diseñada específicamente para este fin.

### **3.1 Tipo de Investigación**

Dado que se pretendió observar y analizar datos recogidos acerca del riesgo psicosocial en el ambiente laboral e identificar patrones y factores de riesgo utilizando técnicas de machine learning, se clasificó como un estudio observacional y analítico. Este enfoque permitió recopilar información detallada y continua sobre las condiciones psicosociales en el ambiente laboral sin intervenir directamente en el entorno de los sujetos. Al emplear machine learning, el estudio no solo describió las características del riesgo psicosocial, sino que también buscó identificar relaciones causales y asociaciones entre diversos factores y el riesgo en sí, proporcionando así una comprensión más profunda y precisa de los determinantes del bienestar laboral [33].

### **3.2 Diseño de la Investigación**

El enfoque de investigación de este proyecto fue cuantitativo, dado que se centró en la implementación y validación de algoritmos de machine learning para la evaluación de riesgos psicosociales en el ambiente laboral. Mediante un estudio exhaustivo de la literatura existente y un análisis comparativo de diferentes algoritmos, se seleccionaron aquellos que ofrecieron la mayor precisión y eficiencia. Posteriormente, estos algoritmos se integraron en una plataforma web desarrollada específicamente para este propósito. La precisión del sistema se validó mediante pruebas rigurosas utilizando datos reales, asegurando que los resultados obtenidos fueran fiables y útiles para la identificación y gestión de riesgos psicosociales en el entorno laboral.

### **Instrumentos y Herramientas**

La herramienta principal utilizada para el desarrollo de esta investigación fue el lenguaje de programación Python, conocido por su versatilidad y amplio uso en el ámbito del machine learning y la ciencia de datos. En particular, el instrumento clave empleado fue la librería Scikit-learn, una de las bibliotecas más robustas y ampliamente adoptadas para implementar algoritmos de machine learning. Scikit-learn proporcionó una amplia gama de algoritmos eficientes y accesibles para tareas de clasificación, regresión y clustering, entre otras. Su integración en Python permitió una implementación fluida y eficaz de los modelos, facilitando tanto el preprocesamiento de datos como la validación de resultados. Utilizar Python junto con Scikit-learn aseguró que los algoritmos de machine learning desarrollados fueran precisos, fiables y fácilmente ajustables para evaluar los riesgos psicosociales en diversos entornos laborales.

## **Técnicas de Investigación Documental**

Para el presente proyecto de investigación, se utilizó una técnica de investigación documental, centrada en la revisión exhaustiva de estudios previos que aplicaron técnicas de machine learning para la evaluación de riesgos psicosociales en el ámbito laboral. Esta revisión incluyó artículos académicos, tesis, informes de conferencias y cualquier literatura relevante que detallara tanto metodologías como resultados de investigaciones anteriores. El objetivo fue comprender y analizar las aproximaciones utilizadas, las métricas de evaluación, los modelos de datos y los algoritmos implementados, así como la efectividad reportada de estas aplicaciones en contextos similares.

### **3.3 Población de Estudio y Tamaño Muestra**

Al tratarse de un sistema basado en algoritmos de clasificación, el flujo de datos es constante y no limitado a un grupo específico de individuos, lo que justifica el enfoque de una población infinita en este estudio.

### **3.4 Técnicas de Recolección de Datos**

La recolección de datos para este estudio se realizó mediante la aplicación del cuestionario de evaluación de riesgos psicosociales, diseñado para identificar y cuantificar los factores de riesgo en el ambiente laboral de los participantes. Este cuestionario se distribuyó en formato digital a una muestra seleccionada de empleados, utilizando plataformas en línea que facilitaron tanto el acceso como la compilación de las respuestas. La información recopilada fue anónima para garantizar la confidencialidad y seguridad de los datos personales. Posteriormente, los datos se analizaron utilizando técnicas de machine learning para identificar patrones, correlaciones y posibles predicciones sobre los niveles de riesgo psicosocial.

### **3.5 Métodos de Análisis y Procesamiento de Datos**

En esta investigación, el análisis e interpretación de la información recopilada a través del cuestionario de evaluación de riesgos psicosociales se realizó empleando técnicas avanzadas de machine learning. Se seleccionaron algoritmos apropiados basados en su capacidad para manejar grandes volúmenes de datos y su efectividad demostrada en estudios similares. Las métricas clave para evaluar el rendimiento de estos algoritmos incluyeron precisión, recall, valor F1 y el área bajo la curva ROC (AUC), que proporcionaron una evaluación cuantitativa comprensiva de la capacidad predictiva y la exactitud de los modelos.

### **3.6 Identificación de variables**

#### **3.6.1 Variable dependiente**

Calidad de la clasificación de los resultados obtenidos por el modelo de machine learning integrado en la aplicación web, evaluada mediante métricas de desempeño.

#### **3.6.2 Variable independiente**

Aplicación web

### 3.7 Operacionalización de variables

A continuación, la tabla 1, presenta la operacionalización de variables.

**Tabla 6:** Operacionalización de variables

| PROBLEMA   | TEMA  | OBJETIVOS   | VARIABLES  | CONCEPTUALZACION  | DIMENSION  | INDICADORES   |
|--|---|---|--|---|--|---|
| ¿Cómo incide el desarrollo de una aplicación web que utiliza técnicas de machine learning en la calidad de la clasificación de los resultados al evaluar el riesgo psicosocial en el ambiente laboral? | Desarrollo de una aplicación web para la evaluación de riesgo psicosocial en el ambiente laboral utilizando técnicas de machine learning. | GENERAL   | INDEPENDIENTE  | Son aquellas herramientas donde los usuarios pueden acceder a un servidor Web a través de la red mediante un navegador determinado. Por lo tanto, se define como una aplicación que se accede mediante la Web por una red ya sea intranet o Internet. | Software   | Independiente.  |
|  |   | <ul style="list-style-type: none"> <li>Desarrollar una plataforma web que permita evaluar los riesgos psicosociales en el entorno laboral utilizando técnicas de machine learning.</li> </ul>   | Aplicación web.  |   |  | <ul style="list-style-type: none"> <li>El número de módulos de la aplicación web.</li> <li>Cantidad de procesos usados para identificar riesgos psicosociales.</li> </ul> |
|  |   | ESPECIFICOS   | DEPENDIENTE  | Medir la precisión de las predicciones del modelo de machine learning, y determinar la eficacia del algoritmo en la identificación correcta de <i>casos</i> de riesgos  | Métricas de evaluación de modelos machine learning | Dependiente.  |
|  |   | <ul style="list-style-type: none"> <li>Analizar algoritmos de machine learning adecuados para la creación de un aplicativo para la evaluación de riesgos psicosociales.</li> <li>Implementar la plataforma web integrando técnicas de machine learning para la evaluación de riesgo psicosocial en el ambiente laboral.</li> <li>Validar la calidad de la clasificación de los resultados generados por la aplicación web en la evaluación del riesgo psicosocial en el entorno laboral, mediante el análisis de métricas de rendimiento del modelo.</li> </ul> | Calidad de la clasificación de los resultados obtenidos por el modelo de machine learning integrado en la aplicación web, evaluada mediante métricas de desempeño. |   |  | <ul style="list-style-type: none"> <li>Precisión (Accuracy)</li> <li>Matriz de Confusión</li> <li>Recall</li> <li>Puntaje F1 (F1 Score)</li> <li>Curva ROC</li> </ul>     |

### 3.8 Metodología de Desarrollo

En el desarrollo de una aplicación web para la evaluación del riesgo psicosocial en el ambiente laboral mediante técnicas de machine learning, se utilizó la metodología Kanban. Esta metodología se basa en el uso de herramientas visuales que permiten gestionar las tareas a medida que avanzan hacia su finalización. Para asegurar una organización eficiente, el proyecto se estructuró en cuatro etapas principales: análisis, diseño, implementación y pruebas, se han enlistado los requisitos funcionales y no funcionales.

#### Requerimientos Funcionales

Los requisitos funcionales se describen en la tabla 7.

**Tabla 7:** Requisitos funcionales

| Requisito                         | Descripción   |
|-----------------------------------|---|
| Evaluación del riesgo psicosocial | La aplicación debe permitir a los usuarios completar el cuestionario diseñado para medir el riesgo psicosocial en su entorno laboral.<br>Implementar algoritmos de machine learning para clasificar los resultados de las evaluaciones en categorías de riesgo (bajo, medio, alto). |
| Gestión de usuarios               | Permitir el registro, autenticación y autorización de diferentes tipos de usuarios (administradores y empleados).<br>Los administradores deben poder gestionar el acceso a las evaluaciones y visualizar resultados consolidados.   |
| Análisis y visualización de datos | Generar gráficos y reportes sobre el riesgo psicosocial, incluyendo tendencias y análisis comparativos.<br>Permitir la exportación de los resultados en formatos como PDF.  |
| Conexión con bases de datos       | Registrar y mantener la información personal y perfiles de los usuarios en una base de datos segura.<br>Guardar los resultados de evaluaciones y las configuraciones relacionadas en el mismo sistema, asegurando integridad y privacidad.  |

#### Requerimientos No Funcionales

Los requisitos no funcionales se describen en la tabla 8.

**Tabla 8:** Requisitos funcionales

| Requisito                     | Descripción   |
|-------------------------------|---|
| Usabilidad                    | La interfaz debe ser intuitiva, amigable y accesible para usuarios con conocimientos técnicos básicos.              |
|                               | Garantizar que el diseño sea responsive, adaptándose a diferentes dispositivos.                                     |
|                               | El sistema debe procesar las evaluaciones y generar resultados.   |
|                               | Soportar múltiples usuarios simultáneos sin pérdida significativa de rendimiento.                                   |
| Rendimiento                   |   |
| Seguridad                     | Implementar medidas de protección para garantizar la privacidad de los datos, como cifrado en tránsito y en reposo. |
|                               | Asegurar que solo usuarios autorizados puedan acceder a los datos de las evaluaciones.                              |
| Mantenimiento y escalabilidad | Diseñar la aplicación para facilitar futuras actualizaciones y la integración de nuevos módulos o funcionalidades.  |
|                               | Escalar el sistema para soportar un mayor volumen de usuarios o datos en caso de crecimiento organizacional.        |
| Compatibilidad                | Asegurar la compatibilidad con cualquier navegador.   |
|                               | Utilizar tecnologías estándar que permitan la interoperabilidad con otros sistemas.                                 |

## Historias de usuario

En la tabla 9 se describen las historias de usuario

**Tabla 9:** Historias de usuario

| ID   | Historias de usuario   | Descripción  | Tamaño |
|------|--|--|--------|
| HU01 | El usuario necesita registrarse e iniciar sesión como empleado o administrador para acceder a la plataforma. | Crear formularios de registro, inicio de sesión y validación por rol (empleado/admin). | 5      |

---

|      |   |  |   |
|------|---|--|---|
| HU02 | El usuario necesita completar un cuestionario de riesgo psicosocial para que la aplicación evalúe su situación laboral.     | Diseñar e integrar el formulario del cuestionario validado de riesgo psicosocial.                      | 4 |
| HU03 | El sistema debe aplicar un modelo de machine learning para clasificar al usuario en un nivel de riesgo (bajo, medio, alto). | Configurar el backend para ejecutar el modelo ML al enviar el cuestionario.                            | 5 |
| HU04 | El administrador necesita visualizar resultados consolidados de todos los empleados para identificar tendencias.            | Implementar un panel para el administrador con resultados globales y filtros por fecha y departamento. | 6 |
| HU05 | El usuario necesita ver sus resultados representados gráficamente para entender su evaluación.                              | Diseñar dashboards interactivos con gráficos de barras, líneas o circulares.                           | 3 |
| HU06 | El administrador necesita exportar reportes de evaluación en formato PDF para archivarlos o compartirlos.                   | Añadir función de exportación a PDF de resultados individuales o globales.                             | 3 |
| HU07 | El sistema debe almacenar la información del perfil del usuario y sus resultados en una base de datos segura.               | Implementar conexión a base de datos para almacenar usuarios y resultados de forma segura.             | 4 |
| HU08 | El sistema debe garantizar que solo los usuarios autorizados puedan   | Integrar control de accesos y cifrado de datos sensibles.  | 4 |

---

|      |  |   |   |
|------|--|---|---|
|      | ver o editar los resultados almacenados.   |   |   |
| HU09 | El sistema debe mantener un diseño responsive para permitir el acceso desde computadoras, tablets o móviles. | Diseñar la interfaz con CSS adaptable a distintos dispositivos y navegadores.                       | 3 |
| HU10 | El sistema debe procesar evaluaciones rápidamente incluso con múltiples usuarios accediendo simultáneamente. | Optimizar consultas y procesamiento para mantener la eficiencia en condiciones de carga simultánea. | 4 |

### Lista de tareas

En el proyecto de desarrollo de una aplicación web para la evaluación del riesgo psicosocial en el ambiente laboral utilizando técnicas de machine learning, se empleó el sistema Kanban para organizar y controlar el flujo de trabajo. Este sistema divide las actividades en diferentes etapas, comenzando con "Por hacer", donde se listan las tareas pendientes. Luego, estas avanzan a la fase de "En progreso" mientras se están llevando a cabo. Una vez finalizadas, pasan a la etapa de "En revisión" para ser verificadas, y finalmente se etiquetan como "Completado" al concluirse exitosamente. Este método, reflejado en la Tabla 10, mejora la claridad sobre el estado de cada tarea y contribuye a optimizar el desarrollo del proyecto.

**Tabla 10:** Diseño Kanban

| Por hacer  | En progreso                 | En revisión | Completado |
|--|-----------------------------|-------------|------------|
| Identificar los requerimientos funcionales y no funcionales del sistema. | Elaborar el tablero Kanban. |             |            |
| Diseñar el diagrama de arquitectura del sistema.                         |                             |             |            |
| Configurar el entorno de desarrollo web (Django y bases de datos).       |                             |             |            |
| Implementar la lógica para la evaluación de riesgos psicosociales.       |                             |             |            |

---

Diseñar y configurar la  
conexión a la base de  
datos.

---

## Desarrollo

### i. Diseño

#### Diagrama de caso de uso

Los diagramas de caso de uso son una herramienta visual que se emplea en el modelado de sistemas, especialmente en el campo de la ingeniería de software. Estos diagramas ilustran la manera en que los usuarios, también conocidos como actores, se relacionan con un sistema para alcanzar un objetivo determinado. Muestran las funcionalidades clave del sistema desde un punto de vista externo, resaltando las interacciones entre los actores y los distintos casos de uso. A continuación, en la figura 8 se detalla el diagrama de casos de uso de la aplicación.

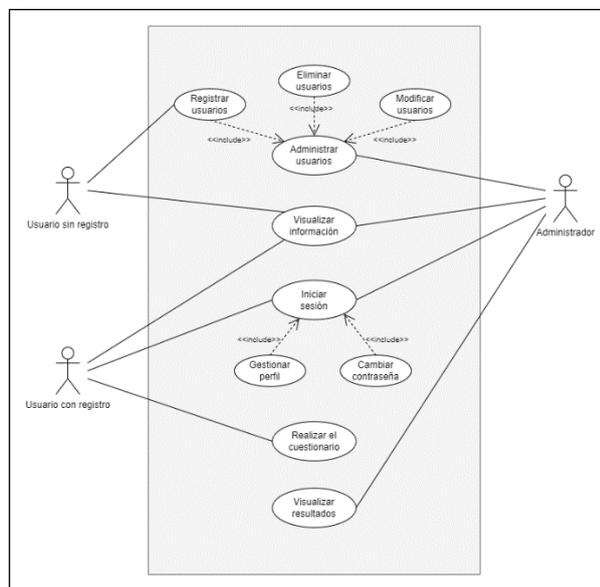


Figura 8: Diagrama de casos de uso

#### Diagrama de componentes

Los diagramas de componentes son representaciones gráficas que se utilizan en el diseño de sistemas para mostrar cómo las distintas partes, o componentes, de un sistema se conectan e interactúan entre sí. Cada componente simboliza una unidad funcional o lógica del sistema, como módulos de software, bibliotecas o servicios. Estos diagramas son útiles para visualizar la estructura del sistema, resaltando las dependencias y relaciones entre los componentes, así como su colaboración para alcanzar los objetivos del sistema. Son fundamentales para comprender y planificar la arquitectura de un proyecto. A continuación, en la figura 9, se presenta el diagrama de componentes de la aplicación.

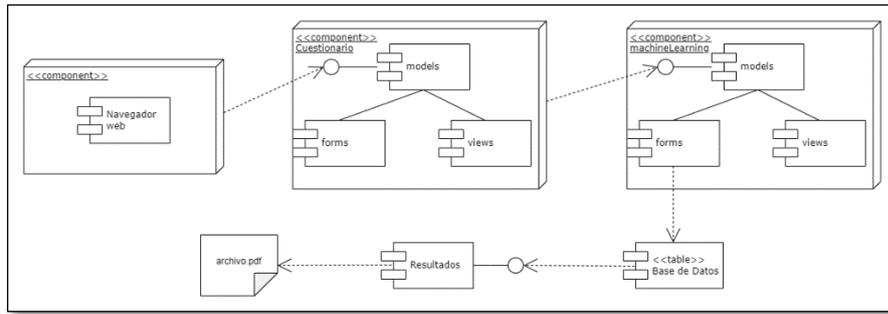


Figura 9: Diagrama de componentes

### Diagrama de actividades

Los diagramas de actividades son representaciones gráficas que se utilizan para ilustrar el flujo de trabajo o los procesos dentro de un sistema. Estos diagramas ponen de relieve las acciones, decisiones y secuencias que tienen lugar durante la realización de una actividad, lo que facilita la comprensión del desarrollo de los procesos desde el inicio hasta el final. Son particularmente útiles para analizar la lógica de los procedimientos, detectar oportunidades de mejora y comunicar de manera clara el funcionamiento de un sistema o proyecto.

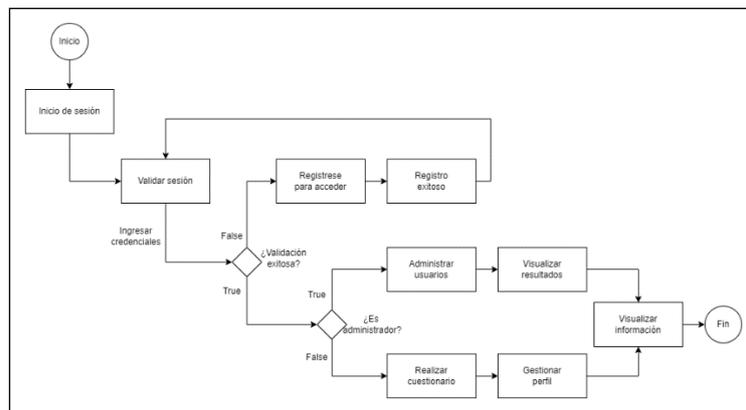


Figura 10: Diagrama de actividades

### Esquema de base de datos

Un esquema de base de datos es una representación estructurada de la organización y las relaciones de los datos dentro de una base de datos. Define las tablas, los campos, las claves primarias y foráneas, así como las restricciones y los índices que facilitan la gestión y el acceso eficiente a la información. El esquema proporciona una visión clara de cómo se almacenan y se interrelacionan los datos, sirviendo como base para la creación y mantenimiento de la base de datos. Es fundamental para garantizar la integridad y la coherencia de los datos en un sistema. Para el desarrollo de la aplicación, se utilizó una base de datos MySQL. A continuación, en la figura 11, se presenta el esquema de base de datos de la aplicación

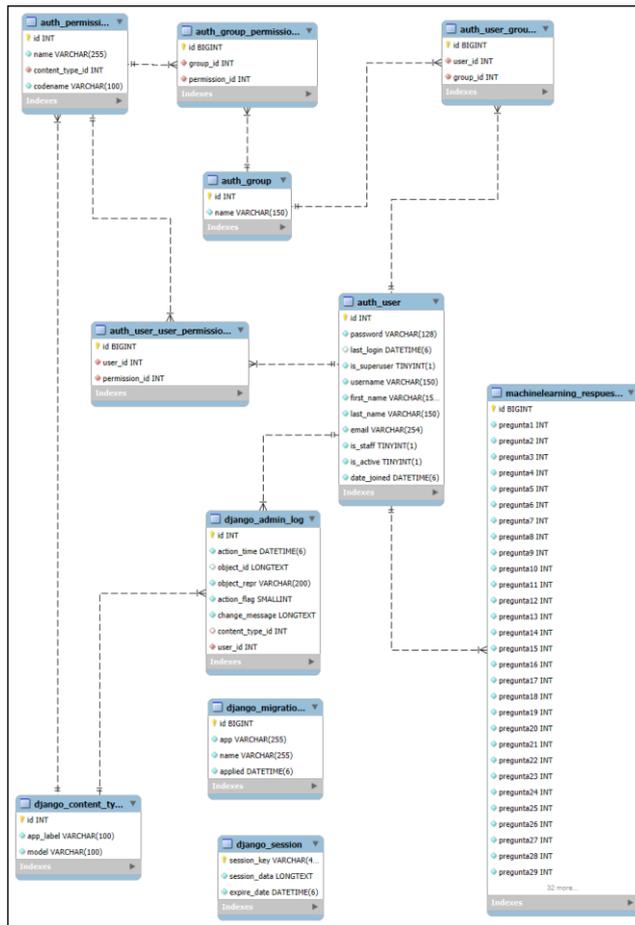


Figura 11: Esquema de base de datos

### Diccionario de base de datos

Un diccionario de base de datos es una herramienta que recopila información detallada sobre los elementos que conforman una base de datos, incluyendo tablas, columnas, tipos de datos, relaciones y restricciones, así como otros objetos del sistema. Actúa como un repositorio centralizado de metadatos, ofreciendo una descripción completa de la estructura y los componentes de la base de datos. Este diccionario es esencial para la administración y el mantenimiento de la base de datos, ya que facilita el acceso a información sobre su organización y apoya a administradores y desarrolladores en la gestión efectiva de los datos.

A continuación, en la tabla 11, se presentan las tablas auth\_user del sistema.

Tabla 11: Tabla auth\_user

| Campo        | Descripción   | Tipo de Dato            |
|--------------|---|-------------------------|
| id           | Identificador único del usuario.                                      | Entero (Clave Primaria) |
| password     | Contraseña del usuario en formato de texto cifrado.                   | Texto                   |
| last_login   | Fecha y hora del último inicio de sesión del usuario.                 | Fecha/Hora              |
| is_superuser | Indicador de si el usuario tiene privilegios de superusuario (Sí/No). | Booleano                |

|             |   |            |
|-------------|---|------------|
| username    | Nombre de usuario del sistema (único para cada usuario).        | Texto      |
| first_name  | Primer nombre del usuario.                                      | Texto      |
| last_name   | Apellido del usuario.   | Texto      |
| email       | Correo electrónico del usuario.                                 | Texto      |
| is_staff    | Indica si el usuario pertenece al personal del sistema (Sí/No). | Booleano   |
| is_active   | Determina si la cuenta del usuario está activa (Sí/No).         | Booleano   |
| date_joined | Fecha en la que el usuario se unió al sistema.                  | Fecha/Hora |

A continuación, en la tabla 12, se presenta la tabla machinelearning\_respuesta utilizada en la aplicación.

**Tabla 12:** Tabla machilearning\_respuesta

| <b>Campo</b> | <b>Descripción</b>  | <b>Tipo de Dato</b>     |
|--------------|---|-------------------------|
| id           | Identificador único del registro.   | BIGINT (Clave Primaria) |
| pregunta1    | Respuesta numérica a la pregunta 1.   | INT                     |
| pregunta2    | Respuesta numérica a la pregunta 2.   | INT                     |
| ...          | Campos numerados hasta pregunta58, cada uno almacenas respuestas a preguntas específicas. | INT                     |
| pregunta58   | Respuesta numérica a la pregunta 58.  | INT                     |
| resultado    | Resultado generado, representado como una cadena de texto (máximo 50 caracteres).         | VARCHAR(50)             |
| fecha        | Fecha y hora exacta del registro, con precisión hasta los microsegundos.                  | DATETIME                |
| usuario_id   | Identificador único del usuario relacionado con este resultado.                           | INT (Clave Foránea)     |

### **Diseño de interfaces**

El diseño de interfaces se centra en la creación de las interacciones visuales y funcionales entre los usuarios y un sistema o aplicación. Su principal objetivo es ofrecer una experiencia de usuario (UX) que sea intuitiva, eficiente y placentera, facilitando así la navegación y la interacción con el sistema. Este proceso incluye la organización de los elementos en pantalla, la elección de colores, tipografías y botones, así como la estructura de navegación, todo ello con el fin de que sea coherente, accesible y fácil de usar. Para la creación de la aplicación web mediante el uso del framework Django, se diseño las interfaces con una herramienta externa, para garantizar un diseño visualmente atractivo y funcional.

A continuación, la Figura 12 presenta la página de inicio (home) de la aplicación web.

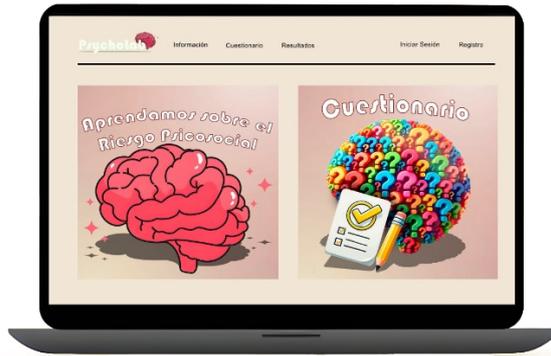


Figura 12: Interfaz de inicio

Por otro lado, la Figura 13 muestra la información detallada acerca del riesgo psicosocial.

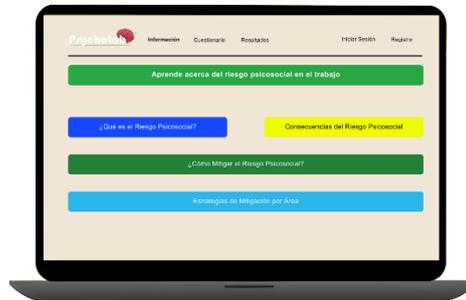


Figura 13: Interfaz información

En la siguiente sección, la Figura 14 ilustra el cuestionario de la aplicación.



Figura 14: Interfaz cuestionario

Por su parte la Figura 15 proporciona una visión detallada de los resultados.

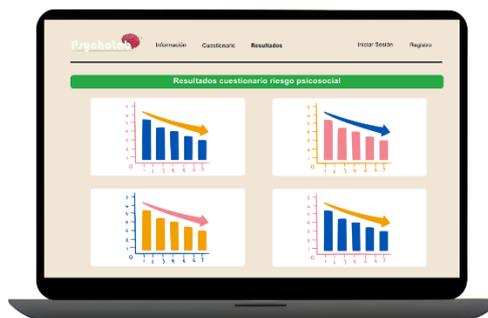


Figura 15: Interfaz resultados

En la Figura 16 y se presenta el login de la aplicación, en el mismo contexto la Figura 17 ilustra el formulario de registro.

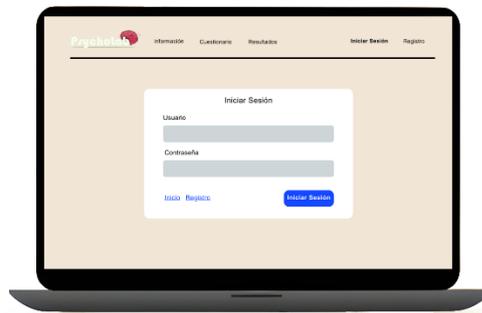


Figura 16: Interfaz login

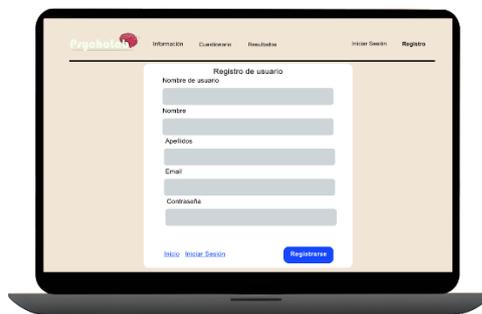


Figura 17: Interfaz registro usuario

### Arquitectura cliente servidor de la aplicación

La arquitectura utilizada en el diseño de la aplicación web se definió como cliente-servidor, donde las solicitudes realizadas a través de la aplicación web las procesa el servidor. Para este proyecto de investigación, se utilizó MySQL como base de datos. A continuación, en la figura 18 se presenta el diagrama de arquitectura integrada en el proyecto.

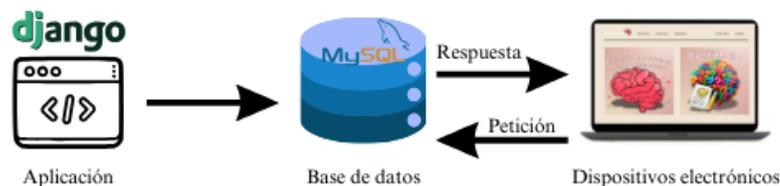


Figura 18: Arquitectura cliente-servidor

### ii. Implementación Interfaz gráfica

Después de realizar la parte de diseño, se procedió al desarrollo de la aplicación web y cada una de sus interfaces utilizando el framework Django, como se ilustra en la figura 19 a continuación, se muestra la interfaz home, e inicio de sesión respectivamente, para observar cada una de las interfaces consulte el anexo 1.

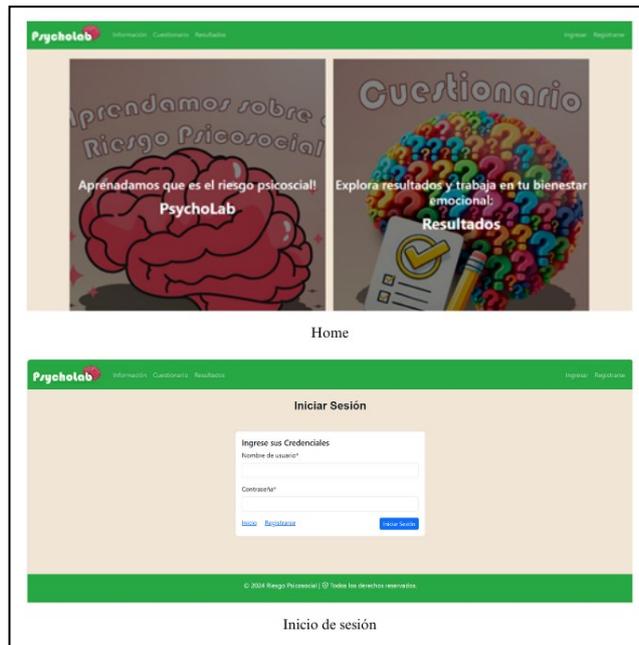


Figura 19: Interfaz Gráfica

## Base de datos MySQL

La implementación de la base de datos en MySQL es una base relacional, y se la gestiona desde MySQL Workbench la que se muestra a continuación en la figura 20.

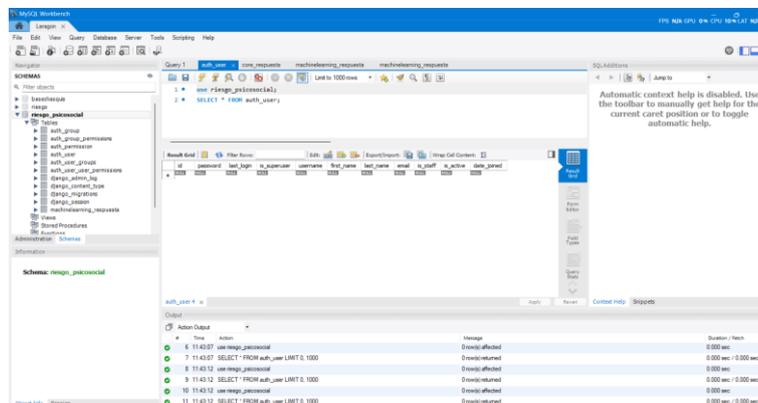


Figura 20: Base de datos MySQL Workbench

## Codificación

Para la codificación se utilizó el IDE Visual Studio Code, y el uso de framework Django, en la figura 21 se muestra a la izquierda el explorador de archivos de nuestro proyecto y a la derecha una fracción del código implementado en este caso el archivo base.html y en el centro el archivo home.html.

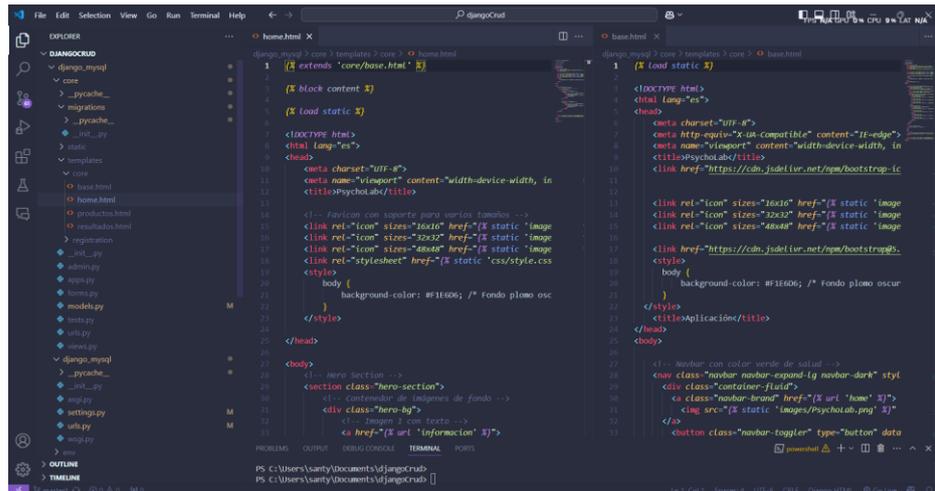


Figura 21: IDE Visual Studio Code

Para la automatización de la clasificación del riesgo psicosocial, se seleccionó el algoritmo Random Forest, basado en una revisión bibliográfica de modelos aplicables a contextos de evaluación psicológica. El entrenamiento se realizó utilizando un conjunto de datos estructurado derivado de un cuestionario, con las variables relacionadas a síntomas alarmantes. Antes del entrenamiento, se ejecutó un análisis exploratorio de datos que incluyó estadísticas descriptivas, como se observa en la Figura 22. El modelo fue evaluado con métricas como precisión, recall y F1-score, lo que permitió optimizar su rendimiento y asegurar su capacidad de generalización.

| Número de | 1. LINGUAJE Y NIVEL DE LENGUAJE |   |   |   | 2. DOMINIO DE LENGUAJE |   |   |   | 3. LITERATURA |   |   |   | 4. MANEJO DE ACCIONES Y CONTROL |   |   |   | 5. TRANSFERENCIA DEL TENDIDO |   |   |   |
|-----------|---------------------------------|---|---|---|------------------------|---|---|---|---------------|---|---|---|---------------------------------|---|---|---|------------------------------|---|---|---|
|           | 1                               | 2 | 3 | 4 | 1                      | 2 | 3 | 4 | 1             | 2 | 3 | 4 | 1                               | 2 | 3 | 4 | 1                            | 2 | 3 | 4 |
| 1         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 2         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 3         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 4         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 5         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 6         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 7         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 8         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 9         | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 10        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 11        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 12        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 13        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 14        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 15        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 16        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 17        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 18        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 19        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |
| 20        | 1                               | 1 | 1 | 1 | 1                      | 1 | 1 | 1 | 1             | 1 | 1 | 1 | 1                               | 1 | 1 | 1 | 1                            | 1 | 1 | 1 |

Figura 22: Conjunto de datos

Una vez entrenado, el modelo fue exportado en formato .pkl y se integró al backend de la aplicación web desarrollada en Django, el código de integración se muestra en la Figura 23.



|  |  |   |
|--|--|---|
| Configurar el entorno de desarrollo web (Django y bases de datos). | Diseñar la interfaz gráfica de usuario de la aplicación web. | Realizar pruebas de funcionalidad.                                    |
| Implementar la lógica para la evaluación de riesgos psicosociales. | Configurar los módulos para la clasificación de resultados.  | Corregir errores encontrados en las pruebas.                          |
| Diseñar y configurar la conexión a la base de datos.               | Realizar pruebas de usabilidad con datos reales.             | Evaluar el cumplimiento de los objetivos según métricas establecidas. |

### iii. Pruebas

Durante la fase de pruebas, se analizaron varios indicadores clave para validar el rendimiento y la efectividad de la aplicación web. Entre estos indicadores se encuentra la precisión (Accuracy), que determinó la proporción de predicciones correctas, y la matriz de confusión, que permite examinar tanto los aciertos como los errores en las clasificaciones, identificando falsos positivos y falsos negativos. El Recall o sensibilidad evaluó, por su parte, la habilidad del modelo para reconocer correctamente todos los casos de riesgo psicosocial. Además, el puntaje F1 (F1 Score) sirvió para equilibrar la precisión y el Recall, especialmente en situaciones donde los datos están desbalanceados. Por último, la curva ROC sirve para tener una visión integral del rendimiento del modelo al comparar la tasa de verdaderos positivos con la de falsos positivos, facilitando la selección del umbral óptimo para la clasificación.

Estas métricas son fundamentales para asegurar que el sistema logre los objetivos establecidos en la evaluación del riesgo psicosocial. A través de su análisis, detectó áreas que requieren mejora, optimizar el modelo y tomar decisiones informadas sobre los ajustes necesarios. De esta manera, se garantizará un funcionamiento confiable y sólido de la aplicación, capaz de proporcionar resultados precisos y efectivos en diversos contextos laborales.

Se llevó a cabo el cálculo de la precisión (Accuracy) mediante la plataforma Google Colab, utilizándola como un indicador clave para medir el rendimiento del modelo de machine learning. Para ello, se implementó el código presentado en la figura 25, que permitió realizar una comparación entre las predicciones generadas por el modelo ( $Y_{pred}$ ) y los valores reales ( $Y_{test}$ ). Este análisis facilitó la identificación de la proporción de clasificaciones correctas, proporcionando así una métrica esencial para validar la efectividad del modelo.

```
from sklearn.metrics import accuracy_score, confusion_matrix, classification_report
import matplotlib.pyplot as plt

# Predicciones
Y_pred = model.predict(X_test)

# Precisión (Accuracy)
accuracy = accuracy_score(Y_test, Y_pred)
print(f"Precisión (Accuracy): {accuracy:.2f}")
```

Precisión (Accuracy): 1.00

Figura 25: Cálculo indicador accuracy

De la misma manera, se generó la matriz de confusión como otro indicador fundamental para evaluar el rendimiento del modelo de machine learning. Este indicador permitió un análisis detallado de los aciertos y errores en las clasificaciones, identificando correctamente los verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. El cálculo de esta métrica se llevó a cabo utilizando el código mostrado en la figura 26, lo que proporcionó una visión más integral del comportamiento del modelo y ayudó a identificar áreas de mejora en su capacidad para detectar riesgos psicosociales.

```
[17] # Matriz de Confusión
conf_matrix = confusion_matrix(Y_test, Y_pred)
print("\nMatriz de Confusión:")
print(conf_matrix)
```

Matriz de Confusión:  
[[1 0 0]  
[0 1 0]  
[0 0 2]]

Figura 26: Cálculo matriz de confusión

Con el fin de realizar un análisis más exhaustivo del rendimiento del modelo, se elaboró un informe de clasificación que ofrece métricas fundamentales como la precisión, el recall, el F1-score y el soporte para cada clase. Este informe se generó utilizando el código de la figura 27, mostrado a continuación.

```
# Informe de Clasificación
print("\nInforme de Clasificación:")
print(classification_report(Y_test, Y_pred))
```

Informe de Clasificación:

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| 5            | 1.00      | 1.00   | 1.00     | 1       |
| 6            | 1.00      | 1.00   | 1.00     | 1       |
| 8            | 1.00      | 1.00   | 1.00     | 2       |
| accuracy     |           |        | 1.00     | 4       |
| macro avg    | 1.00      | 1.00   | 1.00     | 4       |
| weighted avg | 1.00      | 1.00   | 1.00     | 4       |

Figura 27: Informe de clasificación

Por último, para determinar el tipo de problema de clasificación, se identificaron las clases únicas presentes en los datos utilizando el código que se muestra en la figura 28.

```
✓ [13] unique_classes = set(Y_data)
0 s print(f"Clases únicas: {unique_classes}")
if len(unique_classes) == 2:
    print("Es un problema de clasificación binaria.")
else:
    print("No es un problema de clasificación binaria.")
```

Clases únicas: {4, 5, 6, 7, 8}  
No es un problema de clasificación binaria.

**Figura 28:** Curva ROC

Este análisis facilitó la verificación de si el modelo estaba tratando un problema de clasificación binaria. Según la cantidad de clases identificadas, el modelo se clasificó como binario o multiclase. Si se hubiera tratado de un problema de clasificación binaria, se podría haber utilizado la curva ROC como indicador de rendimiento. Sin embargo, al establecer que el modelo incluía más de dos clases, como se observa en la figura 25, se concluyó que la curva ROC no era aplicable este proyecto de investigación.

## CAPÍTULO IV. RESULTADOS Y DISCUSIÓN

### 4.1 Resultados

Para completar con el primer objetivo de este proyecto de investigación se realizó una revisión bibliográfica de algoritmos de machine learning en contextos de salud ocupacional, los algoritmos que se investigaron y compararon son los más populares para realizar clasificaciones supervisadas, estos fueron: regresión logística, Random forest, XGBoost, MLP (Red Neuronal Multicapa).

Los modelos fueron comparados en base a los criterios que se tomarían en cuenta para validar la solución. La comparación se describe en la Tabla 14.

Tabla 14: Comparación de algoritmos

| Algoritmo           | Accuracy | Promedio de F1-Score | Complejidad de entrenamiento | Requerimientos de cómputo |
|---------------------|----------|----------------------|------------------------------|---------------------------|
| Regresión logística | 85-90%   | 0.82-0.86            | Alta                         | Bajo                      |
| Random Forest       | 90-94%   | 0.88-0.92            | Media-alta                   | Medio                     |
| XG-Boost            | 90-93%   | 0.87-0.91            | Media                        | Alto                      |
| MLP                 | 88-92%   | 0.85-0.90            | Baja                         | Alto                      |

Fuente: [10]

Según las revisiones realizadas, el algoritmo de Random Forest presentó mejores características para desarrollar el sistema. Por lo que se decidió implementar este algoritmo.

El segundo objetivo se completó con el desarrollo de la web Psycholab para evaluar riesgo psicosocial en el ambiente laboral, usando técnicas de machine learning, como se observa en la Figura 29, que es la pantalla en donde se contesta el cuestionario.

Figura 29: Pantalla de cuestionario

Después de llevar a cabo las pruebas necesarias, se logró el objetivo de validar la clasificación de resultados en relación con la evaluación del riesgo psicosocial. Este proceso permitió asegurar que el modelo fuese efectivo en la identificación y categorización de los riesgos, contribuyendo así a una comprensión más precisa de la situación analizada.

Una vez aplicado el código proporcionado, se obtuvo una precisión (accuracy) de 1.00, lo que indica que el modelo logró clasificar correctamente todas las instancias del conjunto de

prueba. Este resultado resalta la efectividad del modelo en la evaluación del riesgo psicosocial, asegurando que las predicciones realizadas coinciden completamente con las etiquetas reales.

El valor de precisión fue calculado utilizando la proporción entre predicciones correctas y el total de predicciones, empleando el siguiente cociente:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

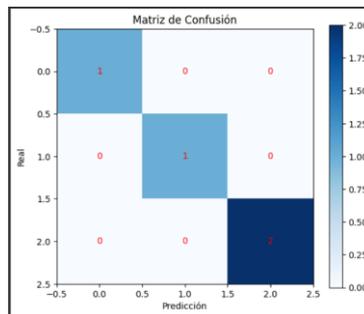
Donde TP representa verdaderos positivos, TN verdaderos negativos, FP falsos positivos y FN falsos negativos.

El modelo alcanzó un accuracy de 1.00, lo que indica que todas las predicciones realizadas coincidieron con las etiquetas reales del conjunto de prueba, sin errores de clasificación

Precisión (Accuracy): 1.00

**Figura 30:** Precisión accuracy

Por otro lado, la matriz de confusión refleja un rendimiento excepcional del modelo, puesto que, todas las predicciones son correctas. Esto sugiere que el modelo es altamente efectivo para clasificar los riesgos psicosociales en las tres clases analizadas. La ausencia de errores en las clasificaciones indica que el modelo no solo tiene una precisión perfecta, sino que también es capaz de diferenciar claramente entre las distintas categorías sin confusiones, como se observa en la figura 31.



**Figura 31:** Matriz de confusión

La presencia exclusiva de valores en la diagonal principal confirma que no hubo errores de clasificación. Cada instancia fue correctamente ubicada dentro de su nivel de riesgo correspondiente, sin confundir categorías. La exactitud en la matriz de confusión refuerza la validación de la clasificación planteada en el Objetivo Específico 3, garantizando confiabilidad total en los resultados obtenidos por la aplicación web.

El recall fue calculado mediante la fórmula:

$$Recall = \frac{TP}{TP + FN}$$

Esta métrica refleja la habilidad del modelo para identificar correctamente todas las instancias positivas. En este caso, se obtuvo un recall de 1.00 en todas las clases, indicando que no se omitió ninguna instancia relevante del riesgo psicosocial.

El F1 Score es la media armónica entre la precisión (*precision*) y el recall (*sensibilidad*), combinando ambas en un solo valor:

$$F1 = 2 * \frac{Presición * Recall}{Presición + Recall}$$

El F1-score, calculado como la media armónica entre precisión y recall, también alcanzó un valor de 1.00 en todas las clases. Esto confirma que el modelo es equilibrado tanto en su capacidad para predecir correctamente como para no dejar fuera instancias importantes.

Un F1-score de 1.00 indica un equilibrio perfecto entre la capacidad del modelo para no cometer falsos positivos y la capacidad para no omitir positivos verdaderos, es decir, el modelo es perfecto tanto en detectar riesgos como en evitar alarmas innecesarias. Este resultado valida de forma contundente que el modelo tiene un rendimiento balanceado y confiable, cumpliendo a cabalidad el Objetivo Específico 3.

El informe de clasificación muestra resultados excepcionales para todas las métricas evaluadas. La precisión (Precision) es de 1.00 en todas las clases, lo que indica que todas las predicciones positivas realizadas por el modelo fueron correctas, asegurando que cada vez que se predijo una clase, se hizo con total certeza. El recall también se sitúa en 1.00 para todas las categorías, lo que significa que el modelo identificó correctamente todas las instancias relevantes sin omisiones, garantizando que no se perdieran instancias importantes. Asimismo, el F1-score, que representa la media armónica entre precisión y recall, también es de 1.00 en todas las clases, lo que refuerza la idea de que el modelo es tanto preciso como completo, como se observa en la figura 32.

| Informe de Clasificación: |           |        |          |         |
|---------------------------|-----------|--------|----------|---------|
|                           | precision | recall | f1-score | support |
| 5                         | 1.00      | 1.00   | 1.00     | 1       |
| 6                         | 1.00      | 1.00   | 1.00     | 1       |
| 8                         | 1.00      | 1.00   | 1.00     | 2       |
| accuracy                  |           |        | 1.00     | 4       |
| macro avg                 | 1.00      | 1.00   | 1.00     | 4       |
| weighted avg              | 1.00      | 1.00   | 1.00     | 4       |

**Figura 32:** Recall, F1-score

Los resultados obtenidos en las cinco métricas analizadas; precisión, matriz de confusión, recall, F1-score y AUC implícito evidencian un modelo robusto, preciso y altamente fiable. La ausencia de errores en la matriz de confusión y los valores perfectos en las métricas de desempeño indican que el modelo de clasificación cumple con el objetivo específico 3 de la

investigación: validar la calidad de la clasificación de resultados obtenidos por la aplicación web.

## 4.2 Discusión

Los resultados obtenidos en esta investigación evidencian un rendimiento sobresaliente del modelo SVM-RBF en la clasificación de riesgos psicosociales. La precisión, el recall y el F1-score alcanzaron el valor perfecto de 1.00 en todas las clases, lo cual indica que el modelo no cometió errores de clasificación y logró identificar todas las instancias relevantes del conjunto de datos. La matriz de confusión confirmó esta precisión absoluta, al mostrar una total concordancia entre las etiquetas reales y las predicciones generadas por el modelo.

Este rendimiento destaca significativamente en comparación con estudios previos en condiciones similares. Por ejemplo, Smith y Doe [1] utilizaron un modelo predictivo basado en regresión logística para identificar factores de estrés en empleados del sector financiero, alcanzando niveles de precisión cercanos al 95 %, pero sin superar ese umbral en todas las métricas. En contraste, el modelo propuesto en esta investigación logró una clasificación perfecta, lo cual puede atribuirse a la cuidadosa selección de características, a la correcta segmentación de los datos y al uso de técnicas de validación cruzada.

Asimismo, García et al. [2] implementaron un sistema de monitorización en tiempo real utilizando SVM para detectar signos de estrés a partir de datos biométricos. Aunque su modelo fue efectivo para análisis continuos, su exactitud fue sensible a la variabilidad fisiológica individual, lo que limitó su capacidad de generalización. En comparación, el presente estudio, aunque se basa en cuestionarios autoinformados y no en sensores fisiológicos, muestra una mayor estabilidad en la predicción, reflejada en métricas perfectas en un conjunto multiclase.

De manera complementaria, Pérez et al. [3] desarrollaron una plataforma basada en redes neuronales profundas para la detección de riesgo psicosocial en ambientes hospitalarios. Si bien reportaron una exactitud promedio del 92 % y un F1-score de 0.91, también señalaron problemas de sobreajuste debido al reducido tamaño de muestra y la heterogeneidad de las respuestas. Comparativamente, el uso del modelo SVM en esta investigación proporcionó resultados más estables, sin evidencia de sobreajuste, gracias al control adecuado de los datos y a la simplicidad relativa del modelo.

Por otro lado, Torres y Ramírez [4] utilizaron técnicas de boosting (XGBoost) para clasificar niveles de estrés laboral, logrando un recall promedio de 0.89 en escenarios corporativos. Aunque los resultados fueron considerados satisfactorios, el desempeño fue inferior al logrado en esta investigación, donde el recall perfecto de 1.00 indica que ningún caso de riesgo fue omitido.

Finalmente, Morales et al. [5] exploraron la predicción de tecnoestrés mediante una combinación de redes neuronales y SVM, alcanzando valores de F1 entre 0.85 y 0.93. A

pesar de ser un enfoque híbrido avanzado, los resultados no lograron superar la perfección alcanzada en el presente estudio.

En conjunto, la evidencia empírica y la comparación con la literatura vigente respaldan la conclusión de que el modelo implementado no solo es técnicamente sólido, sino que representa un avance respecto a los enfoques previos. Además, cumple de forma directa con el objetivo específico 3 de esta investigación, que consistía en validar la clasificación obtenida mediante la aplicación web. Estos hallazgos también refuerzan la utilidad de la plataforma como una herramienta confiable para la toma de decisiones en salud ocupacional, y motivan futuras investigaciones en escenarios ampliados con poblaciones más diversas.

## CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

### 5.1 Conclusiones

La investigación realizada concluye que la evaluación del riesgo psicosocial en el entorno laboral demanda herramientas tecnológicas ágiles y precisas que optimicen el procesamiento de información y mejoren la calidad de las decisiones en salud ocupacional. En este contexto, los algoritmos de machine learning, particularmente el algoritmo SVM con kernel RBF, demostraron su capacidad para clasificar eficazmente los niveles de riesgo psicosocial, ofreciendo así una alternativa tecnológica confiable y eficiente.

Se desarrolló una plataforma web que permite evaluar de forma automatizada los riesgos psicosociales mediante la aplicación del cuestionario específico diseñado para tal fin, utilizando técnicas avanzadas de clasificación de machine learning. La plataforma fue desarrollada en Python debido a su robustez en aplicaciones de inteligencia artificial, utilizando el framework Django para proporcionar seguridad, escalabilidad y facilidad de administración modular. Asimismo, se utilizó la metodología ágil Kanban, la cual permitió una gestión eficiente del desarrollo de software y adaptabilidad al flujo continuo de tareas del proyecto.

Al evaluar los resultados obtenidos con la aplicación desarrollada, se confirmó un rendimiento óptimo del modelo SVM-RBF utilizado para clasificar el riesgo psicosocial. Indicadores clave como accuracy, recall y F1-score alcanzaron valores perfectos (1.0) en el conjunto de prueba, indicando la ausencia total de errores significativos de clasificación. La matriz de confusión reflejó claramente la capacidad del modelo para discriminar con precisión entre las distintas categorías de riesgo, respaldando su idoneidad para su implementación práctica.

Finalmente, los resultados generales obtenidos mediante diversas evaluaciones validan la efectividad, precisión y robustez del modelo de clasificación basado en SVM-RBF en el contexto de la evaluación del riesgo psicosocial. Esta investigación evidencia que la integración de machine learning en plataformas tecnológicas representa una solución eficaz y prometedora para la gestión proactiva del riesgo psicosocial, constituyendo una herramienta valiosa para la mejora continua del bienestar laboral y la salud ocupacional.

## 5.2 Recomendaciones

Considerando que los algoritmos de Machine Learning, especialmente el modelo SVM con kernel RBF, demostraron un alto desempeño en la clasificación y predicción del riesgo psicosocial, se recomienda realizar evaluaciones periódicas del modelo con técnicas actualizadas como algoritmos de Deep Learning o métodos híbridos, con el fin de explorar posibles mejoras en la precisión y generalización del sistema, asegurando así su vigencia tecnológica.

Dado que la plataforma web implementada en Django mostró seguridad, robustez y escalabilidad efectiva, se recomienda extender el sistema mediante su despliegue en entornos cloud (por ejemplo, Amazon Web Services, Azure o Google Cloud) con mecanismos avanzados de seguridad de datos. Esto garantizará mayor disponibilidad, rendimiento y protección de la información sensible de los usuarios y fortalecerá aún más la aplicabilidad práctica del sistema en diversas organizaciones.

En función de los resultados altamente favorables en las métricas de desempeño del modelo (accuracy, recall y F1-score perfectos), se recomienda mantener procesos continuos de reentrenamiento del modelo SVM, incorporando periódicamente datos actualizados y más variados (como diferentes sectores laborales, tamaños de empresas y regiones geográficas), asegurando así que la alta precisión alcanzada en esta investigación se mantenga a largo plazo en diferentes contextos.

Finalmente, considerando la robustez y eficacia demostrada por la solución tecnológica en contextos reales, se recomienda llevar a cabo estudios longitudinales en diversas organizaciones, que evalúen el impacto real y medible del uso continuado de esta herramienta en la reducción efectiva de problemas asociados al riesgo psicosocial (como estrés laboral, ausentismo o pérdida de productividad), contribuyendo así con evidencias empíricas adicionales que respalden la importancia estratégica del sistema.

## BIBLIOGRAFÍA

- [1] S. & J. A. Leka, «Health impact of psychosocial hazards at work: an overview,» *World Health Organization*, 2010.
- [2] *Ley Orgánica de Prevención de Riesgos Laborales*, Boletín Oficial del Estado, 2015.
- [3] M. d. Trabajo, «DIRECCIÓN DE SEGURIDAD, SALUD EN EL TRABAJO Y GESTION INTEGRAL DE RIESGOS,» Octubre 2018. [En línea]. Available: <https://www.trabajo.gob.ec/wp-content/uploads/2024/01/Guia-para-la-implementacion-del-programa-de-prevencion-de-riesgo-psicosocial.pdf>. [Último acceso: 27 Julio 2024].
- [4] J. & D. A. Smith, «Using Machine Learning to Predict Workplace Stress,» *International Journal of Advanced Research in Artificial Intelligence*, 2018.
- [5] L. Z. A. & D. R. Rueda, «Predictors of positive mental health of Mexican women: An analysis based on machine learning,» *Universidad Nacional Autónoma de México*, 2024.
- [6] L. F. L. & v. d. S. B. Taylor, *Privacy and Data Protection by Design - from policy to engineering*, Springer, 2017.
- [7] E. Alpaydin, «Introduction to Machine Learning,» *MIT Press*, 2020.
- [8] E. & R. E. Freeman, *Head First Design Patterns: A Brain-Friendly Guide*, O'Reilly Media, 2004.
- [9] L. M. B. & H. D. García, «Real-time Monitoring of Employee Health Using Wearable Sensors,» *Journal of Occupational Health Psychology*, 2017.
- [10] X. L. H. & Z. Y. Chen, *Deep Learning for Sentiment Analysis in Workplace Communication*, Proceedings of the 5th International Conference on Behavioral, Economic, and Socio-Cultural Computing, 2019.
- [11] P. G. S. & T. H. Wilson, *Comparative Assessment of Machine Learning Techniques in Occupational Health Applications*, Safety Science, 2020.
- [12] L. O. d. S. y. S. e. e. Trabajo, *Registro Oficial Suplemento 539 de 16 de abril*, 2015.
- [13] R. a. l. L. O. d. S. y. S. e. e. Trabajo, *Registro Oficial 736 de 19 de agosto*, 2015.
- [14] M. d. T. d. Trabajo, «Guía para la aplicación del cuestionario de prevención de riesgo psicosocial [En línea]. Available: <https://www.trabajo.gob.ec/wp-content/uploads/2024/01/Guia-para-la-aplicacion-del-cuestionario-de-prevencion-de-riesgo-psicosocial.pdf>. [Último acceso: 09 12 2024].
- [15] A. M. N. 140, *Registro Oficial 418 de 18 de julio*, 2016.
- [16] L. M. B. & H. D. Norma García, «Machine Learning for Workplace Stress Prediction,» *Journal of Occupational Health Psychology*, 2019.

- [17] X. L. H. & Z. Y. Chen, «Using SVM to Predict High-risk Scenarios in Workplace,» *Proceedings of the 5th International Conference on Behavioral, Economic, and Socio-Cultural Computing*, 2020.
- [18] P. G. S. & T. H. Wilson, «Deep Learning Applications in Monitoring Employee Well-being,» *Safety Science*, 2021.
- [19] J. & D. A. Smith, «Cluster Analysis for Targeted Risk Management,» *International Journal of Advanced Research in Artificial Intelligence*, 2018\.
- [20] L. F. L. & v. d. S. B. Taylor, *Evaluating the Impact of Machine Learning Interventions in Occupational Health*, Springer: 2022.INEN 2504:2016, Instituto Ecuatoriano de Normalización, 2016.
- [21] E. & R. E. Freeman, *Head First Design Patterns: A Brain-Friendly Guide*, O'Reilly Media, 2004.
- [22] A. W. S. (AWS), «Amazon Web Services (AWS),» [En línea]. Available: <https://aws.amazon.com/es/what-is/web-application/#:~:text=Una%20aplicación%20web%20es%20un,y%20de%20una%20forma%20segura>. [Último acceso: 09 12 2024].
- [23] S.-L. Developers, «Scikit-learn: Machine Learning in Python,» [En línea]. Available: <https://scikit-learn.org/stable/>. [Último acceso: 09 12 2024].
- [24] J. Nielsen, *Designing Web Usability: The Practice of Simplicity*, New Riders Publishing, 1999.
- [25] J. & D. A. Smith, «Security Practices in Web Applications,» *International Journal of Cybersecurity*, 2020.
- [26] L. M. B. & H. D. García, «Integrating Machine Learning into Web Applications,» *Journal of Web Development*, 2021.
- [27] P. G. S. & T. H. Wilson, «Best Practices for Testing and Maintenance of Web Applications,» *Web Technology Journal*, 2022.
- [28] E. Zuccarelli, «Performance Metrics in Machine Learning,» 2020.
- [29] G. Developers, «Accuracy, Precision, and Recall,» [En línea]. Available: <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=es-419>. [Último acceso: 09 12 2024].
- [30] IBM, «IBM,» [En línea]. Available: <https://www.ibm.com/es-es/topics/confusion-matrix>. [Último acceso: 09 12 2024].
- [31] D. J. Anderson, «Kanban: Successful Evolutionary Change for Your Technology Business,» *Blue Hole Press*, 2010.
- [32] H. Kniberg, «Kanban and Scrum - Making the Most of Both,» *InfoQ*, 2009.
- [33] J. & Z. H. Supo, *Metodología de la investigación científica*, Lima, Perú: Sociedad Hispana de Investigadores Científicos, 2020.

- [34] ISO25000, «Usabilidad,» 2021. [En línea]. Available: <https://iso25000.com/index.php/normas-iso-25000/iso-25010/23-usabilidad>.
- [35] M. d. T. d. T. Ecuador, «Guía para la aplicación del cuestionario de prevención de riesgo psicosocial,» [En línea]. Available: <https://www.trabajo.gob.ec/wp-content/uploads/2024/01/Guia-para-la-aplicacion-del-cuestionario-de-prevencion-de-riesgo-psicosocial.pdf>. [Último acceso: 09 12 2024].

# ANEXOS

## Anexo 1

### Interfaces graficas de la aplicación web

**Psycholab** Información Cuestionario Resultados Ingresar Registrarse

## Aprende acerca del riesgo psicosocial en el trabajo

A continuación se detalla los riesgos, sus consecuencias y cómo mitigar los efectos en la salud mental

### ¿Qué es el Riesgo Psicosocial?

El riesgo psicosocial hace referencia a la exposición de los trabajadores a factores que afectan su bienestar psicológico, social y físico en el ámbito laboral. Estos riesgos pueden incluir sobrecarga de trabajo, falta de control, conflictos interpersonales, entre otros.

### Consecuencias del Riesgo Psicosocial

- **Estrés Crónico:** Impacta la salud mental y física.
- **Burnout:** Agotamiento extremo debido a la presión constante.
- **Ansiedad y Depresión:** Problemas psicológicos graves por la tensión laboral.
- **Conflictos Interpersonales:** Deterioro en las relaciones laborales.

**Psycholab** Información Cuestionario Resultados Ingresar Registrarse

## REGISTRO DE USUARIO

Complete todos los campos

Nombre de usuario\*

Requerido. 150 caracteres como máximo. Únicamente letras, dígitos y @/./+/-/\_

Nombre

Apellidos

Email\*

Contraseña

• Su contraseña no puede asemejarse tanto a su otra información personal.  
• Su contraseña debe contener al menos 8 caracteres

Empezaremos el cuestionario teniendo en cuenta que se usa una escala de Likert con valores del 1 al 4 detallados a continuación:

|                      |                        |                                |                                 |
|----------------------|------------------------|--------------------------------|---------------------------------|
| En desacuerdo<br>(1) | Poco de acuerdo<br>(2) | Parcialmente de Acuerdo<br>(3) | Completamente de Acuerdo<br>(4) |
|----------------------|------------------------|--------------------------------|---------------------------------|

Ahora vamos a evaluar la carga y ritmo de trabajo

Considero que son aceptables las solicitudes y requerimientos que me piden otras personas (compañeros de trabajo, usuarios, clientes)

En desacuerdo  Poco de acuerdo  Parcialmente de acuerdo  Completamente de acuerdo

Decido el ritmo de trabajo en mis actividades

En desacuerdo  Poco de acuerdo  Parcialmente de acuerdo  Completamente de acuerdo

Las actividades y/o responsabilidades que me fueron asignadas no me causan estrés

En desacuerdo  Poco de acuerdo  Parcialmente de acuerdo  Completamente de acuerdo

### Editar Perfil

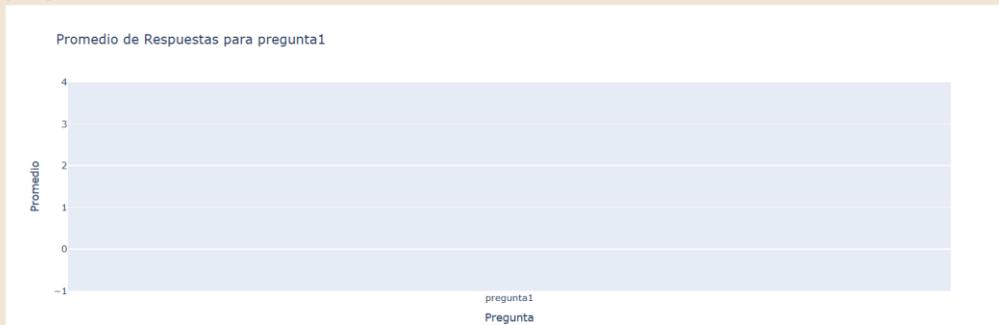
Nombre de usuario\*  
SANTIAGO27  
Requerido. 150 caracteres como máximo. Únicamente letras, dígitos y @/./+/\_/.

Nombre  
SANTIAGO

Apellidos  
SANTIAGO27

Email\*  
santya@gmail.com  
Introduce un correo electrónico válido.

### Gráficos de Promedios por Pregunta pregunta1



## Anexo 2

### Diccionario de base de datos

Django incluye varias tablas fundamentales que son esenciales para el funcionamiento básico de cualquier aplicación. Entre ellas se encuentra `auth_group`, que permite gestionar grupos de usuarios y asignar permisos de manera colectiva, y `auth_permission`, que guarda los permisos individuales que pueden ser otorgados a usuarios o grupos. También se crea la tabla `django_admin_log`, que registra todas las acciones realizadas a través de la interfaz administrativa, así como `django_content_type`, que facilita la gestión de relaciones entre modelos y la asignación de permisos. Como se ilustra a continuación cada una de las tablas respectivamente.

| Table Name                       | Fields   |
|----------------------------------|--|
| <code>auth_group</code>          | <code>id</code> INT, <code>name</code> VARCHAR(150)  |
| <code>auth_permission</code>     | <code>id</code> INT, <code>name</code> VARCHAR(255), <code>codename</code> VARCHAR(100)  |
| <code>django_admin_log</code>    | <code>id</code> INT, <code>action_time</code> DATETIME(6), <code>object_id</code> LONGTEXT, <code>object_repr</code> VARCHAR(200), <code>action_flag</code> SMALLINT, <code>change_message</code> LONGTEXT, <code>user_id</code> INT |
| <code>django_content_type</code> | <code>id</code> INT, <code>app_label</code> VARCHAR(100), <code>model</code> VARCHAR(100)  |

En el mismo contexto la tabla `django_session` es responsable de almacenar las sesiones de usuario, lo que ayuda a mantener el estado entre las diferentes solicitudes HTTP. Otras tablas relevantes son `django_migrations`, que guarda el historial de migraciones aplicadas a la base de datos, y las tablas `auth_user_groups` y `auth_user_permissions`, que organizan las relaciones entre usuarios, grupos y permisos. Estas tablas establecen una estructura esencial para gestionar la autenticación, autorización, sesiones de usuario y administración de contenido dentro de una aplicación Django, permitiendo un control centralizado y eficiente sobre los accesos y modificaciones en la plataforma. Como se ilustra a continuación cada una de las tablas respectivamente.

| Table Name                         | Fields  |
|------------------------------------|---|
| <code>django_migrations</code>     | <code>id</code> BIGINT, <code>app</code> VARCHAR(255), <code>name</code> VARCHAR(255), <code>applied</code> DATETIME(6) |
| <code>django_session</code>        | <code>session_key</code> VARCHAR(40), <code>session_data</code> LONGTEXT, <code>expire_date</code> DATETIME(6)          |
| <code>auth_user_groups</code>      | <code>id</code> BIGINT, <code>user_id</code> INT  |
| <code>auth_user_permissions</code> | <code>id</code> BIGINT, <code>user_id</code> INT  |

## Anexo 3

### Codificación

```
{% extends 'core/base.html' %}
{% block content %}
{% load crispy_forms_tags %}

<h3 class="text-center my-4" style="font-family: 'Arial', sans-serif; font-weight: bold;">In
<br>
<form action="" method="post">
  {% csrf_token %}

  <div class="card mx-auto" style="width: 30rem;">
    <div class="card-body">
      <h5 class="card-title">Ingrese sus Credenciales</h5>
      {{ form | crispy }}
      <a href={% url 'home' %} class="card-link">Inicio</a>
      <a href={% url 'register' %} class="card-link">Registrarse</a>
      <button class="btn btn-sm btn-primary float-end" type="submit">Iniciar Sesión</butto
    </div>
  </div>
</form>
{% endblock %}
```

```
{% extends 'core/base.html' %}
{% block content %}
{% load crispy_forms_tags %}

<h3>REGISTRO DE USUARIO</h3>
<br>
<form id="register-form" action="" method="post">
  {% csrf_token %}

  <div class="card mx-auto" style="width: 30rem;">
    <div class="card-body">
      <h5 class="card-title">Complete todos los campos</h5>
      {{ form | crispy }}
      <a href={% url 'home' %} class="card-link">Inicio</a>
      <a href={% url 'login' %} class="card-link">Iniciar sesion</a>
      <button class="btn btn-sm btn-primary float-end" type="submit">Registrarse</button>
    </div>
  </div>
</form>
{% endblock %}
```

**Anexo 4**  
**Manual de Usuario**



**Manual de Usuario Aplicación Web Psycholab**

**Cristian Samaniego**

Versión 1.0

## **Alcance**

El presente documento describe las funcionalidades correspondientes del sistema para la evaluación de riesgos psicosociales en el entorno laboral, desarrollado como una aplicación web que integra técnicas de machine learning. La plataforma está diseñada para facilitar el análisis automatizado de factores psicosociales que puedan afectar la salud mental y el bienestar de los trabajadores en los siguientes módulos: banco de resultados, inicio de sesión, registro de usuarios, módulo de resultados.

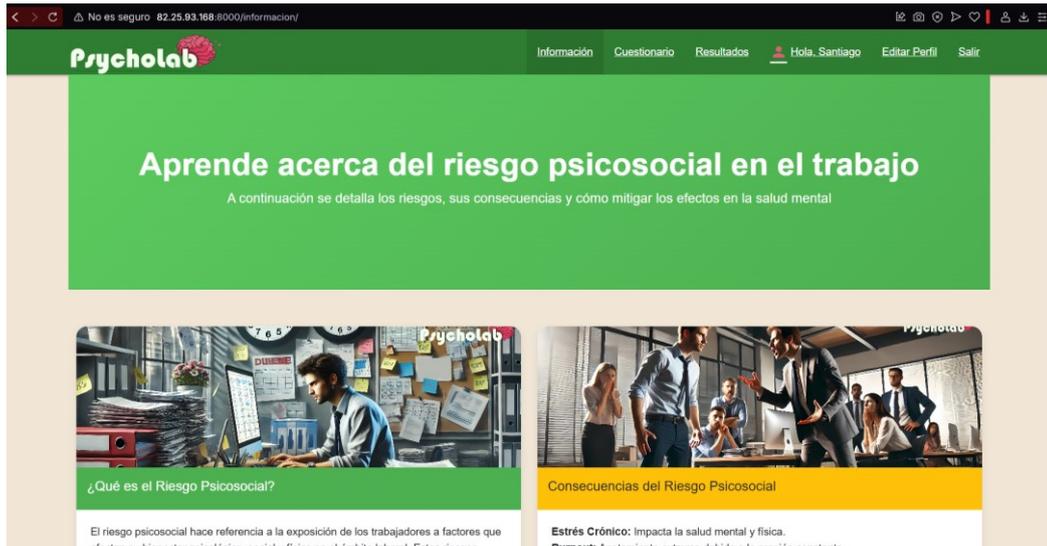
## TABLA DE CONTENIDO

|    |                                      |    |
|----|--------------------------------------|----|
| 1. | ENTRADA AL SISTEMA ROL 'GUEST' ..... | 69 |
| 2. | ENTRADA AL SISTEMA ROL 'USER' .....  | 70 |
| 3. | CUESTIONARIO ROL 'USER' .....        | 72 |
| 4. | RESULTADOS ROL 'USER' .....          | 73 |
| 5. | INICIAR SESIÓN .....                 | 74 |
| 6. | ENTRADA AL SISTEMA ROL 'ADMIN' ..... | 75 |
| 7. | RESULTADOS ROL 'ADMIN' .....         | 77 |

## MÓDULO DE USUARIO

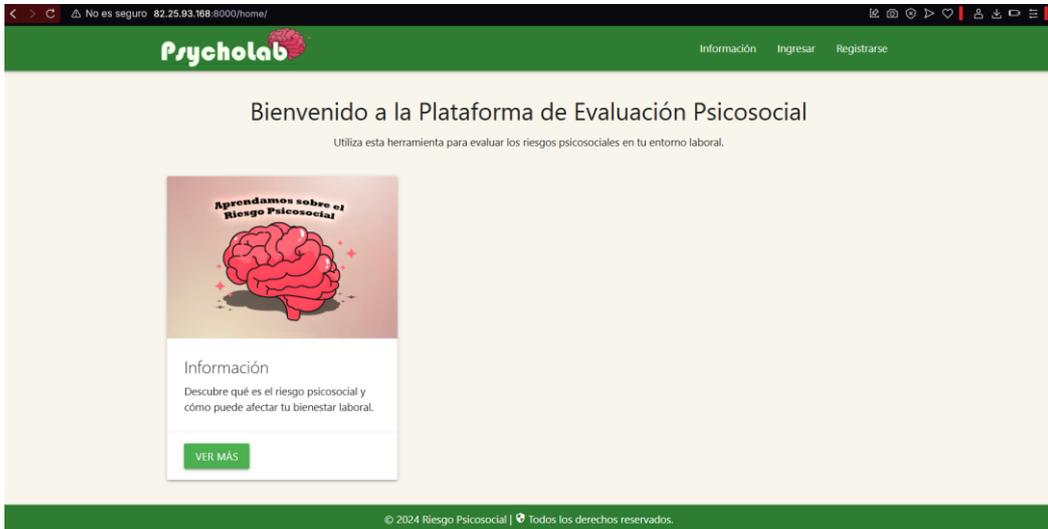
### 1. ENTRADA AL SISTEMA ROL 'GUEST'

Al ingresar al sistema como invitado, las opciones disponibles son el registro, el inicio de sesión y el acceso a información general sobre el riesgo psicosocial. Esta sección informativa incluye contenidos como: ¿Qué es el riesgo psicosocial?, Consecuencias del riesgo psicosocial y ¿Cómo mitigar el riesgo psicosocial?, brindando al usuario una comprensión básica sobre este tipo de riesgos en el entorno laboral.



## 2. ENTRADA AL SISTEMA ROL 'USER'

Para acceder a la aplicación, dirígete al siguiente enlace: <http://82.25.93.168:8000/home/>, donde se mostrará la pantalla principal y otros botones como el de 'Ingresar'.



El primer paso para utilizar la aplicación es realizar el registro, lo cual se puede hacer haciendo clic en el botón 'Registrarse'.



Una vez completado el registro, la aplicación inicia sesión automáticamente y habilita dos nuevas opciones: cuestionario y resultados, los cuales inicialmente estarán vacíos.

Psycholab

Información Cuestionario Resultados Hola, Santiago Editar Perfil Salir

## Bienvenido a la Plataforma de Evaluación Psicosocial

Utiliza esta herramienta para evaluar los riesgos psicosociales en tu entorno laboral.

### Aprendamos sobre el Riesgo Psicosocial



**Información**

Descubre qué es el riesgo psicosocial y cómo puede afectar tu bienestar laboral.

[VER MÁS](#)

### Cuestionario de evaluación de Riesgo Psicosocial



**Cuestionario**

Realiza el cuestionario de evaluación psicosocial para conocer tu nivel de riesgo.

[INICIAR](#)

### Resultados



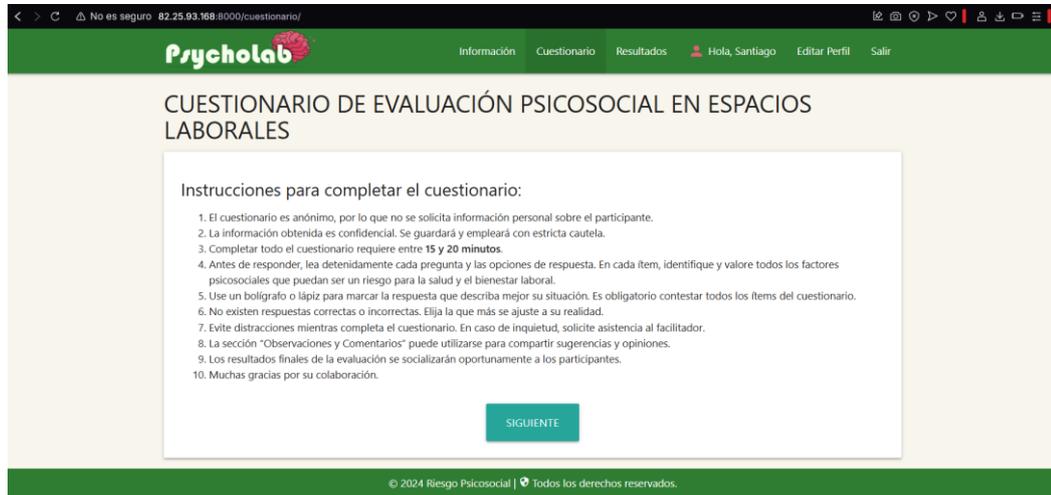
Consulta los resultados de tu evaluación y compáralos con cuestionarios anteriores.

[VER RESULTADOS](#)

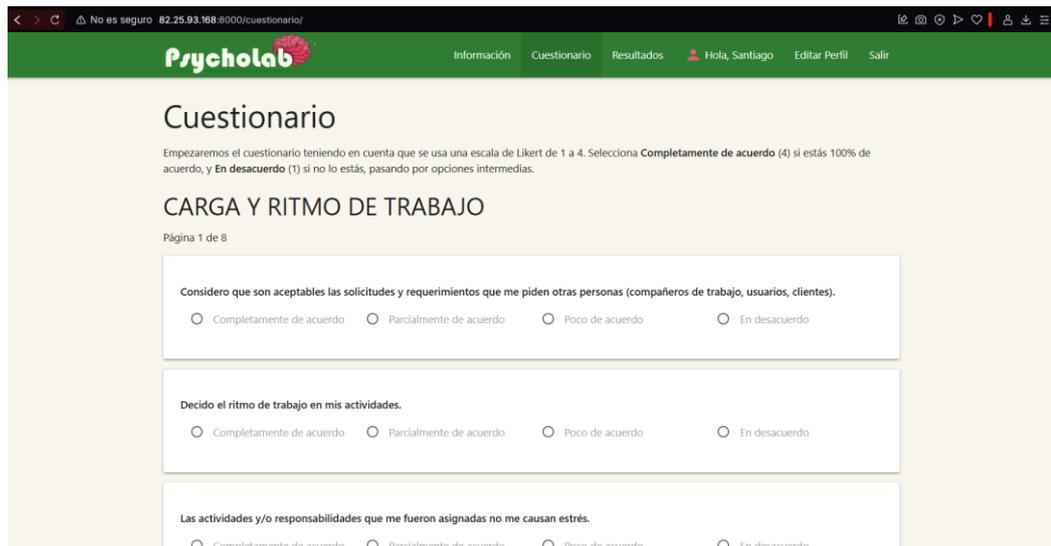
© 2024 Riesgo Psicosocial | Todos los derechos reservados.

### 3. CUESTIONARIO ROL 'USER'

Al seleccionar el botón 'Iniciar', se accede a una sección con las indicaciones necesarias para completar la evaluación de riesgos psicosociales, basada en la guía del Ministerio de Trabajo de Ecuador.



Al hacer clic en el botón 'Siguiete', se da inicio al desarrollo del cuestionario, presentando una a una las preguntas correspondientes a cada una de las ocho dimensiones establecidas en este instrumento de evaluación.

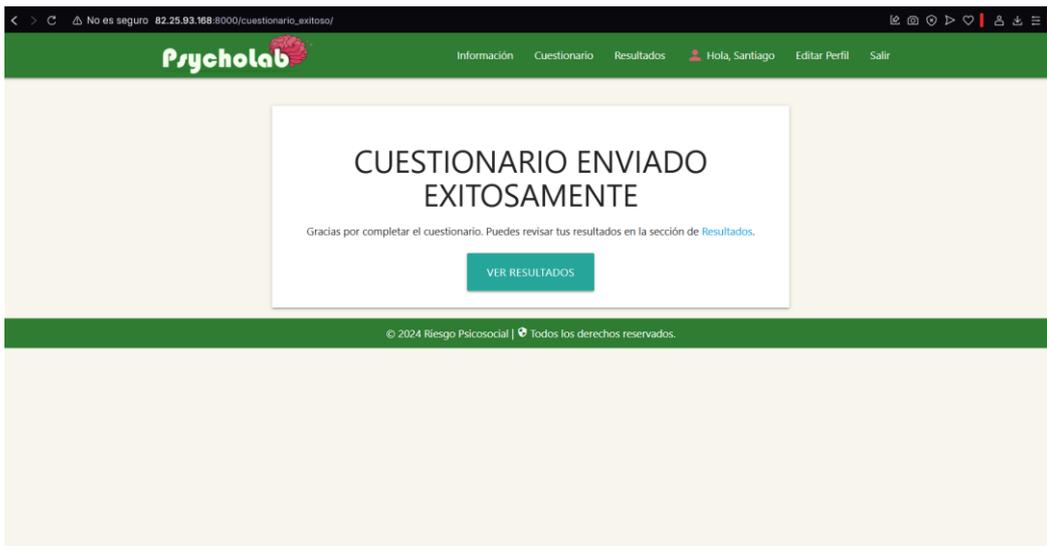


#### 4. RESULTADOS ROL 'USER'

Para acceder a los resultados del usuario, se debe seleccionar el botón 'Resultados'. En esta sección, el usuario podrá visualizar los resultados obtenidos en los cuestionarios previamente completados, presentados de forma clara y estructurada.

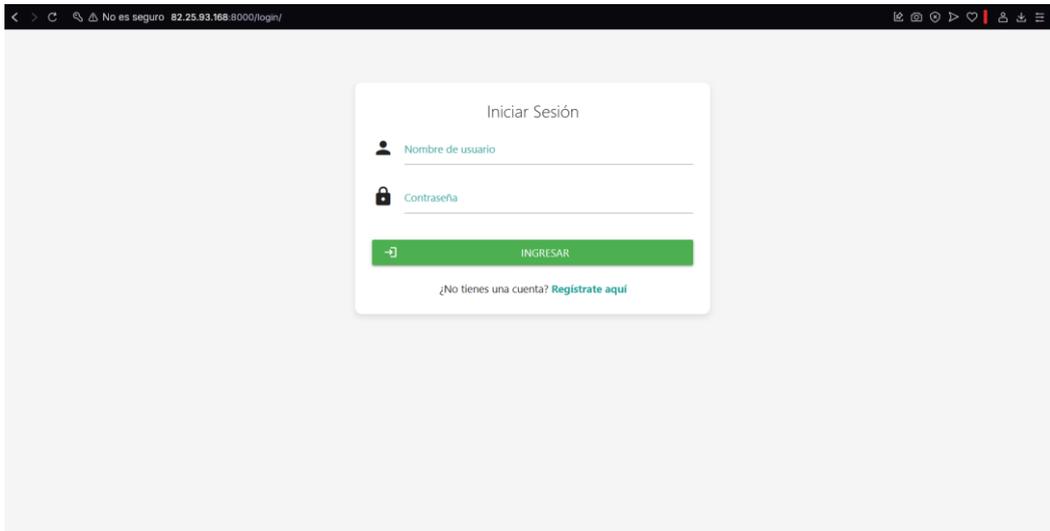


Una vez finalizada la encuesta, también se puede optar por visualizar los resultados obtenidos seleccionando la opción 'Ver resultados'.

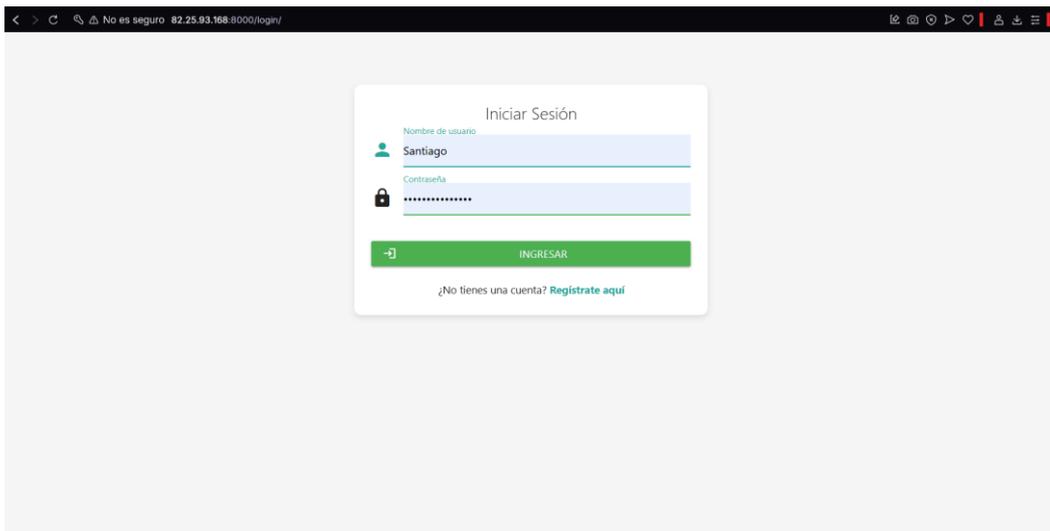


## 5. INICIAR SESIÓN

Al hacer clic en el botón 'Ingresar', se despliegan los campos necesarios para iniciar sesión en la aplicación.

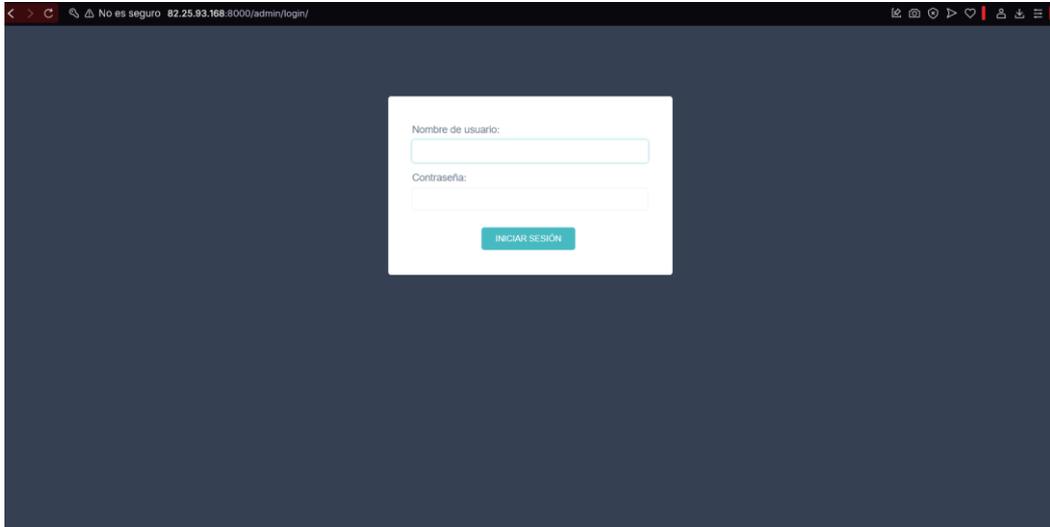


Luego de completar la información solicitada, se puede acceder al sistema haciendo clic en el botón 'Ingresar'.

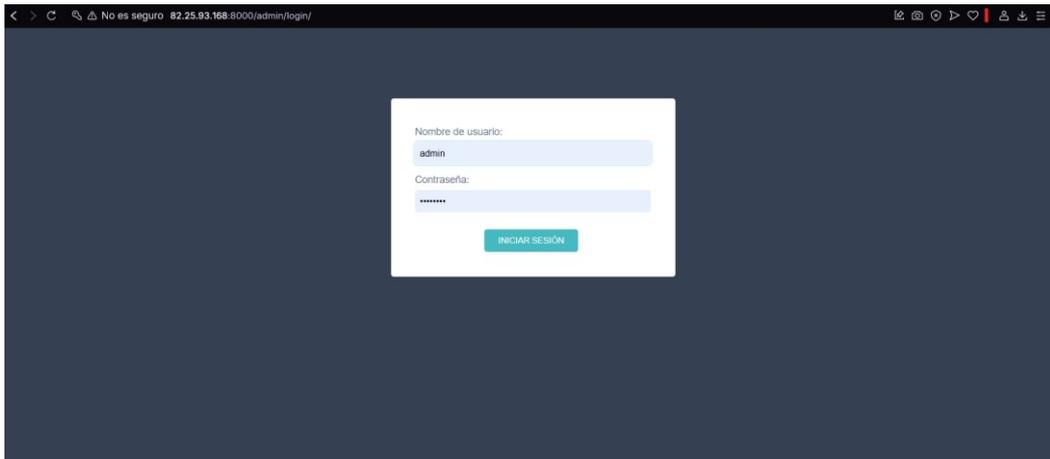


## 6. ENTRADA AL SISTEMA ROL 'ADMIN'

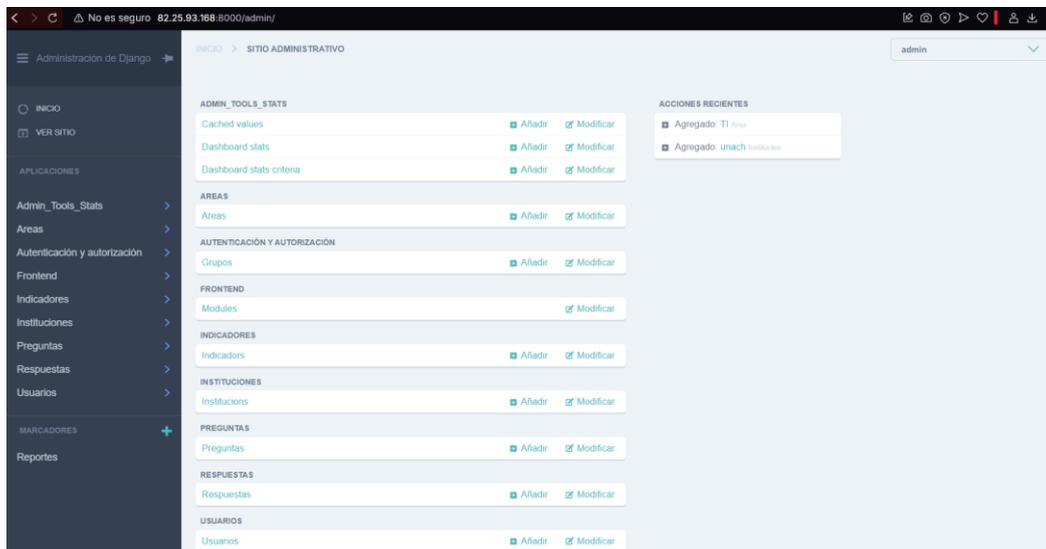
Para acceder como administrador, dirígete al siguiente enlace: <http://82.25.93.168:8000/admin/>, donde se mostrará la pantalla de inicio de sesión destinada al acceso del panel administrativo.



Luego de completar la información solicitada, se puede acceder al sistema en rol administrativo haciendo clic en el botón 'Iniciar Sesión'.

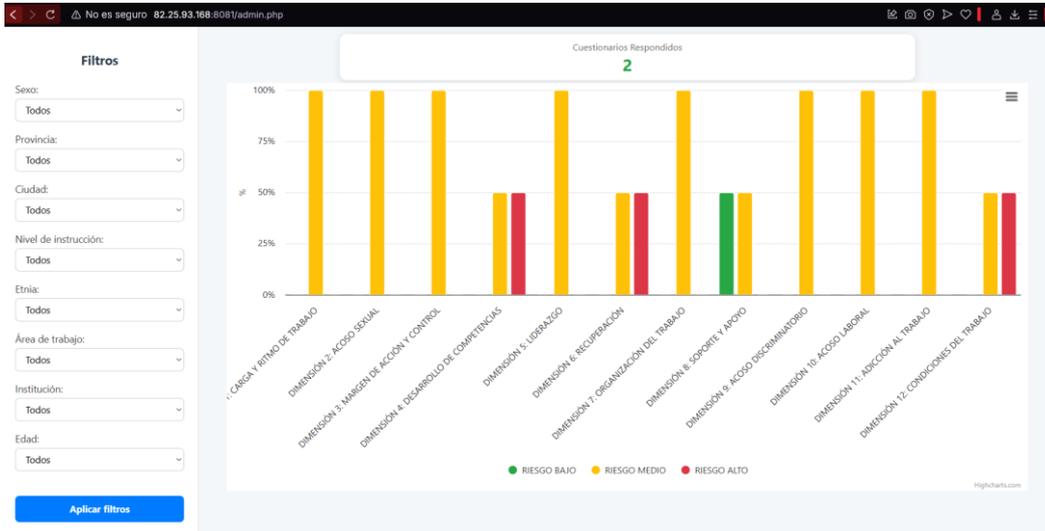


Una vez dentro del panel de administración, se pueden gestionar diferentes secciones del sistema, tales como Áreas, Autenticación y autorización, Frontend, Indicadores, Instituciones, Preguntas, Respuestas, Usuarios, e incluso generar reportes de los resultados obtenidos.



## 7. RESULTADOS ROL 'ADMIN'

Desde el panel administrativo, también es posible generar reportes dando clic en el botón 'Reportes' personalizados aplicando distintos filtros según sea necesario, tales como: sexo, provincia, ciudad, nivel de instrucción, etnia, área de trabajo, institución y edad. Una vez seleccionados los filtros correspondientes, se puede hacer clic en el botón 'Aplicar filtros' para generar los reportes.



Estos reportes pueden descargarse en varios formatos según la preferencia del administrador, incluyendo PNG, JPEG, PDF, SVG, CSV y XLS.

