

UNIVERSIDAD TÉCNICA DE AMBATO



FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E INDUSTRIAL CENTRO DE POSGRADOS

MAESTRÍA EN MATEMÁTICA APLICADA

TEMA: Modelo de predicción de riesgos psicosociales en el transporte urbano de pasajeros usando técnicas de Inteligencia Artificial.

Trabajo de Titulación previo a la obtención del Grado Académico de Magíster en
Matemática Aplicada

Autor: Ingeniero, Amado Antonio Lara Satán

Director: Ingeniero, Edison Fernando Loza Aguirre, PhD.

Ambato – Ecuador

2021

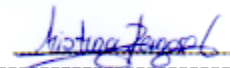
APROBACIÓN DEL TRABAJO DE TITULACIÓN

A la Unidad Académica de Titulación de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial.

El Tribunal receptor de la Defensa del Trabajo de Titulación presidido por la Ingeniera Elsa Pilar Urrutia Urrutia Magíster, e integrado por la señora Ingeniera Cristina Isabel Reinoso Astudillo Doctora y el señor Doctor Freddy Geovanny Benalcázar Palacios Magíster, designados por la Unidad Académica de Titulación de Posgrados de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial de la Universidad Técnica de Ambato, para receptor el Trabajo de Titulación con el tema: “MODELO DE PREDICCIÓN DE RIESGOS PSICOSOCIALES EN EL TRANSPORTE URBANO DE PASAJEROS USANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL”, elaborado y presentado por el señor Ingeniero, Amado Antonio Lara Satán, para optar por el Grado Académico de Magister en Matemática Aplicada; una vez escuchada la defensa oral del Trabajo de Titulación el Tribunal aprueba y remite el trabajo para uso y custodia en las bibliotecas de la Universidad Técnica de Ambato.



Ing. Elsa Pilar Urrutia Urrutia, Mg.
Presidente y Miembro del Tribunal de Defensa



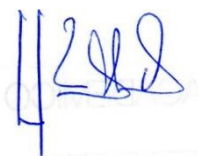
Ing. Cristina Isabel Reinoso Astudillo, Dra.
Miembro del Tribunal de Defensa



Dr. Freddy Geovanny Benalcázar Palacios, Mg.
Miembro del Tribunal de Defensa


AUTORÍA DEL TRABAJO DE TITULACIÓN

La responsabilidad de las opiniones, comentarios y críticas emitidas en el Trabajo de Titulación presentado con el tema: **MODELO DE PREDICCIÓN DE RIESGOS PSICOSOCIALES EN EL TRANSPORTE URBANO DE PASAJEROS USANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL**, le corresponde exclusivamente a: Ingeniero, Amado Antonio Lara Satán, Autor bajo la Dirección de Ingeniero, Edison Fernando Loza Aguirre, PhD, Director del Trabajo de Investigación; y el patrimonio intelectual a la Universidad Técnica de Ambato.



Ing. Amado Antonio Lara Satán

AUTOR




Ing. Edison Fernando Loza Aguirre, PhD.

DIRECTOR

DERECHOS DE AUTOR

Autorizo a la Universidad Técnica de Ambato, para que el Trabajo de Investigación, sirva como un documento disponible para su lectura, consulta y procesos de investigación, según las normas de la Institución.

Cedo los Derechos de mi Trabajo de Titulación, con fines de difusión pública, además apruebo la reproducción de este, dentro de las regulaciones de la Universidad Técnica de Ambato.

A handwritten signature in blue ink, appearing to be 'A. Lara Satán', written over a faint horizontal line.

Ing. Amado Antonio Lara Satán

c.c. 0601878531

ÍNDICE GENERAL

Contenido	
PORTADA.....	i
APROBACIÓN DEL TRABAJO DE TITULACIÓN.....	ii
AUTORÍA DEL TRABAJO DE TITULACIÓN	iii
DERECHOS DE AUTOR.....	iv
ÍNDICE DE TABLAS.....	vii
ÍNDICE DE FIGURAS.....	viii
AGRADECIMIENTO.....	ix
DEDICATORIA.....	x
RESUMEN EJECUTIVO.....	xi
EXECUTIVE SUMMARY.....	xiii
CAPITULO I EL PROBLEMA DE INVESTIGACIÓN.....	1
1.1 Introducción.....	1
1.2 Justificación.....	4
1.3 Objetivos.....	5
1.4 Alcance.....	6
CAPÍTULO II ANTECEDENTES INVESTIGATIVOS.....	7
2.1 Inteligencia artificial.....	7
2.2 Aprendizaje automático.....	8
2.3 Riesgos psicosociales.....	19
CAPÍTULO III MARCO METODOLÓGICO.....	21
3.1 Metodología.....	21
3.2 Hipótesis.....	24
3.3 Población y muestra.....	25
3.4 Descripción de instrumentos utilizados.....	25
3.5 Operacionalización de variables.....	26
3.6 Diseño de la investigación basado en la metodología CRISP-DM.....	27
3.7 Aspectos éticos.....	31
CAPÍTULO IV RESULTADOS Y DISCUSIÓN.....	32
4.1 Resultados de la fase de comprensión de datos.....	32
4.2 Resultados de la fase de preparación de datos.....	38

4.3 Resultados de la fase de modelamiento del algoritmo K-Nearest Neighbour (KNN).....	42
4.4 Resultados de la fase de modelamiento del algoritmo Árbol de Decisión (DT).....	45
4.5 Resultados de la fase de modelamiento del algoritmo Máquina de Vectores de Soporte (SVM) con datos sin equilibrar.....	49
4.6 Resultados de la fase de modelamiento del algoritmo Máquina de Vectores de Soporte (SVM) con datos equilibrados.....	54
4.7 Resultados de la fase de evaluación general de los modelos KNN, DT, SVM.....	58
CAPÍTULO V CONCLUSIONES Y RECOMENDACIONES.....	59
5.1 Conclusiones.....	59
5.2 Recomendaciones.....	61
BIBLIOGRAFÍA.....	62
ANEXOS.....	69

ÍNDICE DE TABLAS

	Pág.
Tabla 3-1: Dimensiones de la variable riesgos psicosociales laborales.....	27
Tabla 4-1: Características sociodemográficas de la población.....	32
Tabla 4-2: Prevalencia de exposición a riesgo psicosocial en la UCTUT....	33
Tabla 4-3: Infracciones de tránsito del periodo 2017 – 2018.....	34
Tabla 4-4: Organización y gestión de riesgos psicosociales.....	35
Tabla 4-5: Fiabilidad del instrumento.....	36
Tabla 4-6: Formato de datos e identificación de datos perdidos.....	36
Tabla 4-7: Codificación de variables.....	37
Tabla 4-8: Descripción del conjunto de datos.....	38
Tabla 4-9: Valores resultantes de las variables divididas en “no estrés” y “estrés” por dimensión.....	39
Tabla 4-10: Escalamiento de variables para <i>KNN</i>	41
Tabla 4-11: División del conjunto de datos en entrenamiento y prueba para <i>KNN</i>	42
Tabla 4-12: Predicción de la variable objetivo con <i>KNN</i>	43
Tabla 4-13: Métricas de evaluación del algoritmo <i>KNN</i>	44
Tabla 4-14: División del conjunto de datos en entrenamiento y prueba para <i>DT</i>	45
Tabla 4-15: Composición porcentual del conjunto de datos.....	45
Tabla 4-16: Métricas de evaluación del algoritmo <i>DT</i>	46
Tabla 4-17: Predicción del Árbol de Decisión.....	47
Tabla 4-18: Correlación de datos.....	49
Tabla 4-19: División del conjunto de datos en entrenamiento y prueba para <i>SVM</i>	51
Tabla 4-20: Nivel de estrés predicho con <i>SVM</i> – datos sin equilibrar.....	51
Tabla 4-21: Métricas de evaluación de <i>SVM</i> – datos sin equilibrar.....	52
Tabla 4-22: Nivel de estrés predicho con <i>SVM</i> – datos equilibrados.....	55
Tabla 4-23: Métricas de evaluación de <i>SVM</i> – datos equilibrados.....	56
Tabla 4-24: Resultados de indicadores de evaluación de los algoritmos.....	58

ÍNDICE DE FIGURAS

	Pág.
Figura 2-1: Componentes de la inteligencia artificial.....	8
Figura 2-2: Fases del aprendizaje automático.....	11
Figura 2-3: Fases del entrenamiento y predicción en clasificación.....	11
Figura 2-4: Ejemplo de clasificación binaria.....	12
Figura 2-5: Ejemplo del algoritmo de clasificación <i>K-Nearest Neighbour</i> ...	14
Figura 2-6: Ejemplo del algoritmo de clasificación Máquina de Soporte de Vectores.....	15
Figura 2-7: Ejemplo del algoritmo de clasificación Árbol de Decisión.....	17
Figura 2-8: Ejemplo de Matriz de Confusión.....	18
Figura 3-1: Fases del modelo <i>Cross Industry Standard Process for Data Mining</i>	22
Figura 3-2: Fases del modelo de evaluación de factores psicosociales.....	23
Figura 4-1: Mapa de riesgos psicosociales de la UCTUT.....	33
Figura 4-2: Siniestros de Tránsito periodo 2017 – 2018.....	34
Figura 4-3: Dimensiones divididas en estrés y no estrés.....	39
Figura 4-4: Histogramas por dimensiones de riesgo psicosocial.....	40
Figura 4-5: Valor de <i>k en</i> K-vecinos más cercanos.....	42
Figura 4-6: Matriz de Confusión <i>KNN</i>	44
Figura 4-7: Matriz de Confusión <i>DT</i>	46
Figura 4-8: Árbol de Decisión.....	47
Figura 4-9: Mapa de Calor de la correlación de Spearman.....	49
Figura 4-10: Matriz de Confusión de <i>SVM</i> datos sin equilibrar.....	52
Figura 4-11: Área Bajo la Curva (<i>AUC</i>) de <i>SVM</i> sin datos equilibrados....	53
Figura 4-12: Datos sin equilibrar y equilibrados en <i>SVM</i>	54
Figura 4-13: Matriz de Confusión de <i>SVM</i> con datos equilibrados.....	56
Figura 4-14: Área Bajo la Curva (<i>AUC</i>) de <i>SVM</i> con datos equilibrados...	57

AGRADECIMIENTO

La realización del Trabajo de Titulación es sin lugar a duda, el esfuerzo combinado de varias personas, entre las que se incluyen, familiares, director, amigos y compañeros.

Un agradecimiento especial a mi familia, fuente de mi mayor inspiración y pilar fundamental en el logro de los objetivos que me he propuesto.

Al señor Ing. Edison Loza, PhD., quién supo guiarme con paciencia y sabiduría en el proceso de titulación.

A la Universidad Técnica de Ambato y su cuerpo docente, quienes han compartido sus conocimientos y experiencias en este proceso de enseñanza-aprendizaje y han sabido brindarme su amistad.

Antonio Lara

DEDICATORIA

Este Trabajo de Titulación está dedicado a todas las personas directamente responsables de que se convirtiera en una realidad.

Antonio Lara

UNIVERSIDAD TÉCNICA DE AMBATO

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

CENTRO DE POSGRADOS

MAESTRÍA EN MATEMÁTICA APLICADA

TEMA:

MODELO DE PREDICCIÓN DE RIESGOS PSICOSOCIALES EN EL TRANSPORTE URBANO DE PASAJEROS USANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL.

AUTOR: Ingeniero, Amado Antonio Lara Satán

DIRECTOR: Ingeniero, Edison Fernando Loza Aguirre, PhD.

LÍNEA DE INVESTIGACIÓN:

- Diseño, Materiales y Producción.

FECHA: 4 de enero de 2021

RESÚMEN EJECUTIVO

El trabajo de conductor de autobús urbano es una de las ocupaciones modernas más estresantes y con mayor riesgo. Si bien el uso de nuevas tecnologías ha brindado mayor autonomía y flexibilidad laboral en esta y otras profesiones, también son las responsables de la exposición a riesgos de índole psicosocial lo que conlleva, a su vez, al estrés laboral. En este sentido, la predicción temprana del estrés y consecuentemente, la identificación de sus riesgos asociados permitiría tomar decisiones adecuadas que permitan, la prevención. El presente estudio se enfoca en trabajar en un modelo que permita predecir los riesgos psicosociales en el transporte urbano de pasajeros de la ciudad de Ambato, aplicando técnicas de aprendizaje automático supervisado. Para este efecto, se utiliza el conjunto de datos de riesgo psicosocial laboral de los conductores de transporte urbano de pasajeros obtenidos con el cuestionario Fpsico 4.0. En el estudio se aplica la metodología para la identificación, análisis y evaluación de riesgos psicosociales del INSHT de España y el marco de referencia Cross Industry Standard Process for Data Mining (CRISP-DM). Se realiza la clasificación con algoritmos supervisados no paramétricos: k-vecinos más cercanos,

árbol de decisiones y máquina de vectores de soporte, y se efectúa la predicción con cada uno de ellos. Las métricas de evaluación de los algoritmos usados son el índice Jaccard y F1-score. Los resultados experimentales muestran que el modelo máquina de soporte de vectores con datos equilibrados presenta un mejor rendimiento con una puntuación F1 del 93% y la valoración con Jaccard del 87%.

Descriptor: Aprendizaje automático, árbol de decisiones, conductor de autobús, estrés, f1-score, índice jaccard, k-vecinos más cercanos, máquina de vectores de soporte, métricas de evaluación, riesgos psicosociales.

UNIVERSIDAD TÉCNICA DE AMBATO
FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E
INDUSTRIAL
CENTRO DE POSGRADOS
MAESTRÍA EN MATEMÁTICA APLICADA

THEME:

PSYCHOSOCIAL RISK PREDICTION MODEL IN URBAN PASSENGER
TRANSPORT USING ARTIFICIAL INTELLIGENCE TECHNIQUES.

AUTHOR: Engineer, Amado Antonio Lara Satán

DIRECTED BY: Engineer, Edison Fernando Loza Aguirre, PhD.

LINE OF RESEARCH:

- Design, Materials and Production.

DATE: January 4, 2021

EXECUTIVE SUMMARY

The city bus driver job ranks among the highest risk and most stressful modern occupations. Modern technologies provides greater autonomy and work flexibility, however they also expose drivers to psychosocial risks, which leads to work stress. Consequently, the early prediction of stress and their associated risk, would contribute to make preventive decisions. The objective of this study is to develop a model that allows predicting psychosocial risks in urban passenger transport in the city of Ambato, applying supervised machine learning techniques. For this purpose, we used data set of occupational psychosocial risk of urban bus drivers obtained with the Fpsico 4.0 questionnaire. The study applies the methodology for the identification, analysis, and evaluation of psychosocial risks of the INSHT of Spain and the Cross Industry Standard Process for Data Mining (CRISP-DM) framework. The classification is performed with the three non-parametric supervised algorithms: k-nearest neighbors, decision trees and support vector machine. The evaluation metrics of the algorithms used are the Jaccard index and F1-score. The experimental results show that the support vector machine model shows better performance with an F1 score of 93% and the Jaccard score of 87%.

Keywords: Machine learning, decision tree, bus driver, stress, f1-score, jaccard index, k-nearest neighbors, support vector machine, assessment metrics, psychosocial risks.

CAPÍTULO I

EL PROBLEMA DE INVESTIGACIÓN

1.1. Introducción

El fenómeno del estrés ha sido reconocido como una de las grandes epidemias de la vida laboral moderna; derivada principalmente de las transformaciones que el trabajo ha presentado en las últimas décadas. En este escenario, el estrés ha generado cambios en la relación persona - trabajo, y consecuencias a nivel físico y mental (EU-OSHA, 2010).

El estrés en la organización puede ocasionar absentismo laboral, baja productividad o disminución en la calidad de los servicios. En el trabajador puede incrementar el riesgo de enfermedades gastrointestinales, coronarias, endocrinas y debilitar el sistema inmunológico (Moreno Jiménez, 2012; Siegrist, 1996; Tennant, 2001).

De acuerdo con la Agencia Europea para la Seguridad y Salud en el Trabajo el estrés tiene su origen en los riesgos psicosociales laborales que se definen como aquellos que “se derivan de las deficiencias en el diseño, la organización y la gestión del trabajo, así como de un escaso contexto social del trabajo, y pueden producir resultados psicológicos, físicos y sociales negativos, como el estrés laboral, el agotamiento o la depresión” (EU-OSHA, 2010).

Desde la década del 70 del siglo pasado, una de las formas de identificar los riesgos psicosociales laborales y sus efectos, ha sido mediante la aplicación manual de cuestionarios y procesamiento posterior de la información (INSHT, 2015). Sin embargo, en la actualidad se dispone de técnicas computacionales las cuales, a través del uso de nuevos algoritmos de aprendizaje automático, datos en línea, técnicas estadísticas y de computación de bajo costo; permiten tomar decisiones basadas en fuentes diversas de datos con aplicaciones en varios campos, como manufactura, finanzas, cuidados de la salud, entre otros (Ponce, 2010; De la Garza, 2013).

A nivel mundial existen diversos estudios sobre riesgos psicosociales laborales y su incidencia en los diferentes sectores productivos y de servicios; sin embargo, los estudios utilizando técnicas de aprendizaje automático aún se hallan en pleno desarrollo, debido a que involucra diversas disciplinas del saber cómo la inteligencia

artificial, ciencias de la computación, ciencia de datos, y en el caso de la presente investigación, seguridad y salud ocupacional.

Si bien todas las actividades laborales están relacionadas con los factores de riesgo, algunas, como es el caso de los conductores, tienen mayor preponderancia (Moreno y Báez, 2010).

Aun cuando existen un gran número de estudios sobre riesgos psicosociales en el sector del transporte terrestre, tanto a nivel nacional como mundial, la literatura científica en los últimos cinco años sobre el referido tema en conjunto con el uso de técnicas de aprendizaje automático, son todavía escasas.

Un ejemplo de los estudios realizados es el de Zouhair, A., Hajar, H. & Aimad, K. (2020), titulado: “La aplicación de técnicas de aprendizaje automático para impulsar el análisis del comportamiento: un marco conceptual y una revisión sistemática de la literatura”. En este estudio, se investiga cómo el conductor opera el vehículo en el contexto de la escena de conducción y el entorno circundante. Los hallazgos de la revisión prueban la capacidad de desempeño de las técnicas de aprendizaje automático para evaluar el comportamiento del conductor. Los resultados evidencian que los modelos que aplican técnicas de aprendizaje automático superan a otros enfoques convencionales. No obstante, el uso de modelos aprendizaje automático en el análisis de bases de datos todavía es limitada y se requiere más esfuerzo para obtener resultados generalizables.

Otro ejemplo de investigación en este ámbito es el de Jeevith, H. & Borge, R. (2020), con su trabajo: “Aplicaciones de los métodos de aprendizaje automático para la evaluación de riesgos de ingeniería: una revisión”. El estudio se enfocó en realizar una revisión de las publicaciones que emplean modelos de aprendizaje automático, algoritmo usado y tipo de industria. Los resultados muestran que la industria automotriz lidera la adopción de algoritmos de aprendizaje automático y en cuarto lugar se hallan algunos estudios relacionados con la conducta del conductor. Las redes neuronales artificiales son el método más aplicado mientras que en un lugar intermedio están KNN y SVM en la evaluación de riesgos de ingeniería.

En Colombia, Mosquera, R., Castrillón, O. y Parra, L (2018) en su trabajo titulado: “Predicción de riesgos psicosociales en docentes colombianos de escuelas públicas utilizando técnicas de aprendizaje automático”, realizan el análisis de riesgos

psicosociales en docentes de colegios públicos en Colombia, y para el efecto desarrollan un estudio comparativo con tres modelos de aprendizaje automático para la predicción: redes neuronales artificiales, arboles de decisión y Bayes ingenuo. Los referidos autores en su investigación aplican algoritmos genéticos, algoritmo de la cantidad esperada de la información, algoritmo GainRatioAttributeEval, coeficiente de relación de Pearson y análisis principal de componentes. El conjunto de datos contiene 5340 registros epidemiológicos, correspondientes a evaluaciones psicosociales de los docentes. El mejor desempeño de predicción se obtuvo con el modelo de redes neuronales con una efectividad del 93%.

De igual forma los autores colombianos antes mencionados publicaron un artículo titulado: “Máquinas de vectores de apoyo, clasificador Naïve de Bayes y algoritmos genéticos para la predicción de riesgos psicosociales en docentes de escuelas públicas colombianas” en el cual presentan sus resultados al tratar de pronosticar el grado de riesgo psicosocial en docentes. En el estudio comparan los modelos de Máquinas de Soporte Vectorial (SVM) y Bayes ingenuo, en dos etapas, primero con todas las variables y segundo, reduciendo la dimensionalidad de los datos aplicando: algoritmos genéticos. La base de datos utilizada fue de 3000 encuestas. El método SVM tuvo el mejor desempeño de predicción con una precisión del 96,3%.

De manera similar, López, R. (2017), realiza en España el estudio de “Modelización de la probabilidad de accidente laboral en función de las condiciones de trabajo mediante técnicas Machine Learning”. El propósito del estudio es el análisis predictivo del accidente laboral. Los datos se obtienen de las encuestas nacionales de condiciones de trabajo del año 2011. El tratamiento de datos se realiza mediante redes bayesianas y los resultados reflejan la relación de las condiciones de trabajo en el aumento de la probabilidad de accidente laboral.

La investigación que se llevará a cabo tiene características propias que la diferencian de los estudios antes mencionados. En primer lugar, el ámbito de estudio es el sector del transporte urbano, sector que no ha recibido particular atención en los estudios. En segundo lugar, se enfoca en uno de los tipos de riesgos de la seguridad industrial, en este caso los riesgos psicosociales. En tercer lugar, la población objeto de estudio está compuesta por conductores de autobuses, los cuales ejercen una actividad laboral durante los siete días de la semana que los deja expuestos a diversos riesgos.

1.2. Justificación

El desarrollo de un modelo de predicción de riesgos psicosociales en el transporte urbano de pasajeros aplicando técnicas de aprendizaje automático encuentra su justificación a través de los siguientes aspectos:

Salud ocupacional. La globalización de la economía, los avances científicos y tecnológicos, entre otros, son características de la sociedad contemporánea que han generado cambios significativos en las organizaciones, modelos de gestión y población trabajadora (Leka & Jain, 2010; Saunders, 2019; Unda et al., 2016; S. G. Van den Heuvel, Bakhuys Roozebom, Eekhout, & Venema, 2018).

En este contexto, no es extraño que el mercado laboral haya sufrido una metamorfosis que se evidencia en las modificaciones de los puestos de trabajo y tareas que se ejecutan, que en algunos casos han mejorado la calidad de vida del trabajador, pero también han incrementado la exposición a riesgos psicosociales y como consecuencia de ello, el estrés laboral (Peiró, 2004; Quick, Macik-Frey, & Nelson, 2017; S. G. Van den Heuvel et al., 2018).

El trabajo de conductor de autobús urbano se sitúa entre las ocupaciones modernas con mayor riesgo psicosocial; constituyéndose en una de las profesiones más estresante y menos saludables (Evans & Carrere, 1991; EU-OSHA, 2014; Silva, Lefio, Marchetti y Benoit, 2014). Según la EU-OSHA los conductores del transporte terrestre son los más afectados por estrés laboral al compararlos con otras actividades económicas (33,3% versus 23,7% de media). Los conductores perciben que su actividad laboral requiere un alto nivel de concentración y asocian la falta de control de su actividad con la ocurrencia de accidentes (EU-OSHA, 2014; Bustos, Pareto, & Marchetti, 2016).

Según el informe de la OMS sobre seguridad vial del 2018, la tasa estimada de accidentes de tránsito fatales en España para el 2016, por cada 100.00 habitantes, fue de 4.1; para Chile de 12.5; y Ecuador el 21.3 (WHO, 2018). En el caso ecuatoriano, la tasa está muy por encima del promedio para la región de las Américas que es del 15.6. Con este marco, resulta de interés para el sector del transporte urbano y la sociedad ecuatoriana en general, en particular para los pasajeros, la detección oportuna de los riesgos psicosociales laborales de esta profesión y su posterior tratamiento preventivo.

Económica. La importancia del estudio de riesgos psicosociales en el trabajo para la población económicamente activa también encuentra interés desde el punto de vista

de los costes económico-sociales que suponen para la actividad económica las situaciones de incapacidad temporal, accidentes de trabajo y enfermedades profesionales que de ellos se derivan (S. Van den Heuvel *et al.*, 2017).

Según la EU-OSHA, los costes globales relacionados con accidentes y enfermedades laborales en Europa ascienden a 476.000 millones de euros anuales, lo que significa un 3.3% del PIB europeo (Elsler, Takala, & Remes, 2017), mientras que en América Latina representa alrededor de 500.000 millones de dólares (aproximadamente el 3% del PIB). En el Ecuador la atención médica relacionada con el estrés también genera costos; sin embargo, no existen registros al respecto.

No obstante, la falta de registros sobre los costes que generan los tratamientos del estrés relacionados con el trabajo en el país, el desarrollo del presente estudio resulta trascendente debido a que contribuye a solucionar un problema latente en el sector del transporte urbano de la ciudad de Ambato y además proporciona información para el desarrollo de futuros estudios.

Preventiva. En el pasado, se han desarrollado trabajos sobre la predicción temprana de problemas psicosociales con el propósito de proponer estrategias de prevención oportunas (Mosquera *et al.*, 2016). La predicción del resultado de un factor psicosocial con un grado de exactitud elevado es una de las tareas más interesantes y desafiantes en este ámbito. Como resultado, los métodos de aprendizaje automático se han convertido en técnicas que permiten descubrir e identificar patrones y relaciones entre ellos, a partir de conjuntos de datos complejos, coadyubando en la predicción eficiente de riesgos (Russell, 2013; Barragán, 2015).

Finalmente, el estudio que se desarrolla se relaciona con la pertinencia de la maestría en matemática aplicada y con las líneas de investigación de la UTA: “Materiales y procesos de fabricación para la industria”, sub-línea de investigación: “Mejora de la competitividad y productividad industrial”.

1.3. Objetivos

1.3.1. General

Elaborar un modelo cuantitativo que permita predecir los riesgos psicosociales en el transporte urbano de pasajeros de la ciudad de Ambato, aplicando técnicas de aprendizaje automático.

1.3.2. Específicos

- Analizar un conjunto de datos multidimensionales a través de métodos estadísticos.
- Realizar el modelado predictivo utilizando los datos disponibles y técnicas de aprendizaje supervisado.
- Establecer la inferencia causal entre las variables objeto de estudio.

1.4. Alcance

Con la presente investigación se pretende examinar un tema poco estudiado: los riesgos psicosociales en el sector del transporte urbano de pasajeros aplicando técnicas de aprendizaje automático. Si bien esta clase de riesgos han sido investigados ampliamente con métodos convencionales, el empleo de algoritmos para predecir con un mayor grado de precisión los riesgos es limitado. En el presente trabajo, se efectuará la revisión bibliográfica y se obtendrá información de riesgos psicosociales aplicando encuestas a la población objeto de estudio.

Asimismo, se describirá la manera en que se manifiestan los riesgos psicosociales laborales a través de diversas dimensiones de análisis. En consecuencia, se catalogarán los riesgos como muy elevados, elevados, moderados y adecuados. Dentro del trabajo, se especificarán también las características de los riesgos psicosociales en las cooperativas de transporte urbano de pasajeros objeto de análisis. La información se procesará con el software FPsico 4.0.

Igualmente, el estudio buscará responder la pregunta de investigación ¿qué técnicas de aprendizaje automático permiten un rendimiento superior en la predicción de riesgos psicosociales en el sector del transporte urbano terrestre de la ciudad de Ambato?, y tendrá como propósito conocer la relación teórica entre las variables objeto de análisis. Más aún, se determinará las técnicas de aprendizaje automático afines al tipo de estudio que se realizará, considerando para ello el conjunto de datos que se dispone.

CAPÍTULO II

ANTECEDENTES INVESTIGATIVOS

2.1. Inteligencia artificial

A pesar de que el término Inteligencia Artificial (IA) se presenta a sí misma como novedosa y moderna, la historia nos demuestra lo contrario (Sarkar, Bali, & Sharma, 2018). Sus orígenes se remontan a la época de Aristóteles (384-322 a.C.), cuando el sabio griego propuso explicar determinados estilos de razonamiento deductivo que él llamó silogismos (Ponce, 2010). De allí en adelante han existido diversos avances, unos más significativos que otros, hasta 1956 año en que John McCarthy introdujo formalmente el término “inteligencia artificial” (Russell & Norvig, 2004).

Gran parte del trabajo inicial sobre IA se desarrolló en la década de 1960 y principios de los setenta con programas de control y robots móviles. A principios de los ochenta, prosperaron algunos programas que contenían cierta capacidad para emular el desempeño humano en determinadas tareas. En la primera década del presente siglo los avances han sido significativos, sin embargo, aún queda mucho camino por recorrer (Ponce, 2010).

Existen varias definiciones de IA; sin embargo, entre las más aceptadas en el ámbito académico, está la planteada por Marvin Minsky, uno de los pioneros de la IA, que es enunciada como “...la ciencia de construir máquinas para que hagan cosas que, si las hicieran los humanos, requerirían inteligencia” (Minsky, 1986). De igual manera, hay diversas clasificaciones de IA, pero la de mayor connotación está formulada por Russell y Norvig, la cual contiene cuatro enfoques: Sistemas que piensan como humanos, Sistemas que piensan racionalmente, Sistemas que actúan como humanos y Sistemas que actúan racionalmente (Russell & Norvig, 2004). Algunos de los principales objetivos de la IA abarcan el aprendizaje cognitivo, la representación del conocimiento, el razonamiento, la resolución de problemas y el procesamiento del lenguaje natural (Sarkar et al., 2018).

Del mismo modo que la IA tiene diferentes tipologías, para Escolano *et al*, también tiene varios campos y técnicas de aplicación, como por ejemplo: Machine learning o aprendizaje automático, Fuzzy logic o lógica difusa, Data mining o minería de datos,

Vida artificial, Redes neuronales artificiales, entre otros (Escolano, Cazorla, Alfonso, & Lozano, 2003).

2.2. Aprendizaje automático

El Machine Learning (Aprendizaje Automático, AA, por su traducción en español) es una disciplina en auge, que parte de conceptos y procedimientos computacionales complejos, y tiene aplicaciones concretas en casi la mayoría de los aspectos de nuestras vidas. Debido a su capacidad para realizar predicciones a partir de los datos disponibles, tiene un gran potencial para mejorar la toma de decisiones en todas las etapas de los procesos organizacionales, sean públicos o privados.

Los avances en la IA, particularmente en el desarrollo de nuevos algoritmos y modelos a partir de los datos capturados de eventos o comportamientos del mundo real es lo que se denomina AA (internetsociety, 2017); mientras que para Samuel, citado por Swamynathan (2019), el AA es un "campo de estudio que brinda a las computadoras la capacidad de aprender sin estar programadas explícitamente" (Swamynathan, 2019).

El AA comparte objetivos y herramientas con otras disciplinas de mayor trascendencia, como las ciencias computacionales, ciencia de datos, estadística e IA (Figura 2-1); y aun cuando existe la suficiente literatura especializada sobre ellas, todavía hay cierta confusión en las características que las diferencian como es el caso de la estadística, inteligencia artificial y aprendizaje automático.

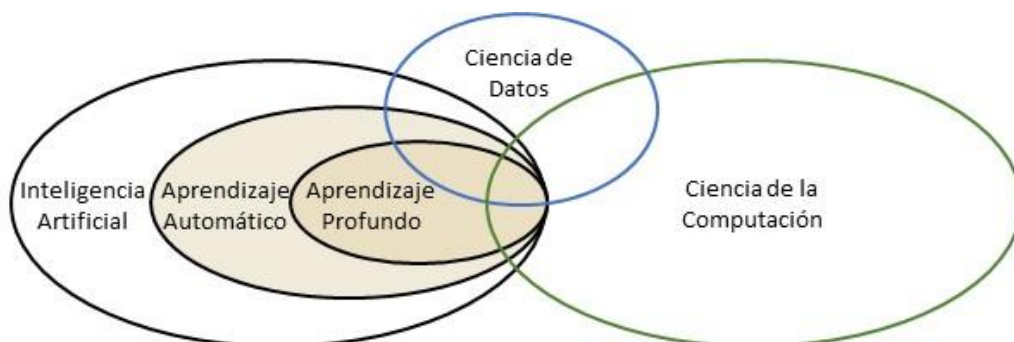


Figura 2-1: Componentes de la inteligencia artificial

Nota. Tomado de Goodfellow *et al* (2016). IA, AA y aprendizaje profundo tienen más aspectos en común que diferencias.

El AA se centra en la búsqueda de patrones en un conjunto de datos para elaborar predicciones sobre lo que sucederá en el futuro y se sirve para ello de la informática. Mientras que la estadística se dedica más al aprendizaje de modelos que se centran en

el análisis de un conjunto de observaciones. En el caso del AA y la IA comparten gran parte de los procedimientos, pero se distinguen por sus objetivos, el primero se propone conseguir decisiones basados en datos, el segundo se plantea reproducir los comportamientos humanos de forma artificial.

El AA consiste en una serie de métodos, modelos y algoritmos que se utilizan para el análisis de datos. Es una disciplina con contenido técnico propio, procedimientos, conocimientos y metodologías. En donde el énfasis recae sobre los datos, que son los que determinan la calidad del resultado, más aún que la elección de los algoritmos que se utilicen.

El progreso reciente del AA ha sido impulsado por el desarrollo de nuevos algoritmos de aprendizaje, por el incremento sustancial de la disponibilidad de datos en línea y por la computación de bajo costo. La adopción de métodos de AA intensivos en datos se puede encontrar en toda la ciencia, la tecnología, producción de bienes y servicios, lo que conlleva a una mejor toma de decisiones basadas en conjunto de datos, en aspectos como la salud, manufactura, educación, servicios financieros, actividades de seguridad y marketing (Jordan et al., 2015; Stajic et al., 2015).

El proceso básico de esta disciplina es proporcionar datos de entrenamiento a un algoritmo de aprendizaje. El algoritmo genera un nuevo conjunto de reglas, basado en inferencias de los datos. En esencia, esto genera un nuevo algoritmo, denominado formalmente el modelo de AA. Al usar diferentes datos de entrenamiento, el mismo algoritmo de aprendizaje podría usarse para generar diferentes modelos.

Inferir nuevas instrucciones de los datos es la fortaleza central del AA. También destaca el papel crítico de los datos: cuantos más datos estén disponibles para entrenar el algoritmo, más aprenderá. De hecho, muchos avances recientes en IA no se han debido a innovaciones radicales en los algoritmos de aprendizaje, sino a la enorme cantidad de datos habilitados por Internet.

Aunque un modelo de aprendizaje automático puede aplicar una combinación de diferentes técnicas, los métodos de aprendizaje generalmente se pueden clasificar en cuatro tipos generales (Raschka & Mirjalili, 2017): aprendizaje supervisado, aprendizaje no supervisado, aprendizaje por refuerzo, y aprendizaje profundo.

Aprendizaje supervisado. El algoritmo de aprendizaje recibe datos etiquetados y la salida deseada. Existe entonces al menos un dato que corresponde a la “respuesta” del

conjunto de datos etiquetados y, por tanto, el algoritmo de aprendizaje tratará de explicar esta respuesta a partir de los demás datos. También se le conoce como aprender de los ejemplares.

Aprendizaje no supervisado. Los datos proporcionados al algoritmo de aprendizaje no están etiquetados y se le pide al algoritmo que identifique patrones en los datos de entrada. No existe una respuesta que deba ser explicada por los datos.

Aprendizaje por refuerzo. Se encuentra entre el aprendizaje supervisado y no supervisado. El algoritmo interactúa en un entorno dinámico que proporciona retroalimentación en términos de recompensas y castigos. Al algoritmo se le indica cuando la respuesta es incorrecta, pero debe explorar y probar diferentes posibilidades hasta averiguar la respuesta correcta (Marsland, 2015). En este caso, el algoritmo no parte de datos previos, sino que los construye por sí mismo en base a sus experiencias.

Aprendizaje profundo. Es un campo muy especial del AA en que las computadoras pueden aprender y tomar decisiones inteligentes por su cuenta. Se basa en la construcción de redes neuronales para extraer modelos predictivos en entornos con muchas variables. El aprendizaje profundo implica un nivel más profundo de automatización en comparación con la mayoría de los algoritmos de AA.

Por otro lado, los cuatro componentes del AA (Figura 2-2) que permiten ir de los datos a la toma de decisiones son (Shah, 2016):

Comprensión de datos. Consiste en la explicación de las características básicas del conjunto de datos, identificación de herramientas estadísticas y formas de visualización de los datos, sean estos unidimensionales, bidimensionales o multidimensionales.

Hacer predicciones. Radica en el uso de métodos, modelos o algoritmos de aprendizaje supervisado o no supervisado, con el propósito de utilizar el conjunto de datos para entrenar a la máquina a aprender, generando funciones que permiten predecir eventos.

Tomar decisiones. Se fundamenta en el análisis de distintos marcos de decisiones y modelos que se aplican en la toma de decisiones.

Determinar inferencias causales. Busca comprobar si las decisiones tomadas han tenido el efecto previsto.

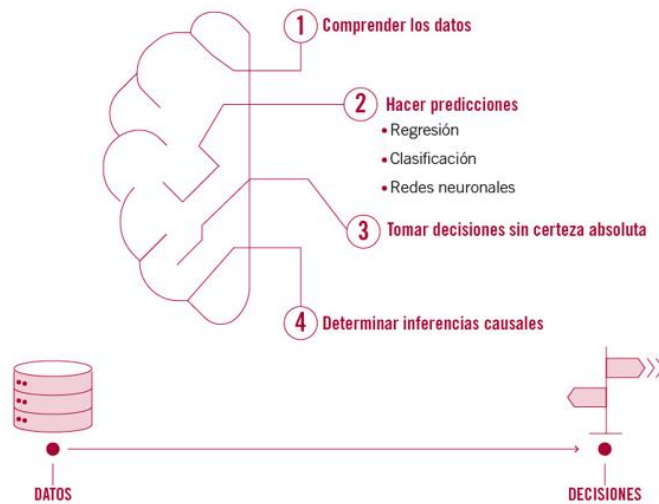


Figura 2-2: Fases del aprendizaje automático

Nota. Tomado de Shah (2016). En AA una de las fases de mayor relevancia es la comprensión de datos. En la fase de predicciones se pueden aplicar algoritmos supervisados y no supervisados.

Técnicas de aprendizaje supervisado

En AA supervisado hay dos tipos de algoritmos principales denominados regresión y clasificación. En regresión, el objetivo es predecir un número continuo, esto es un valor cualquiera dentro de una escala. Mientras que en clasificación el propósito es predecir una etiqueta de clase (Mueller & Guido, 2016). El factor más relevante en clasificación es que el resultado es discreto, donde cada ejemplo pertenece a una clase y el conjunto de clases cubre la totalidad del espacio de salida posible (Marsland, 2015).

La clasificación (Figura 2-3) se basa en un conjunto de entrenamiento etiquetado que permite aprender un conjunto de parámetros del modelo. Posteriormente este modelo se aplica a datos sin etiquetar con el objeto de predecir la clase a la que pertenece cada instancia (Julian, 2016).

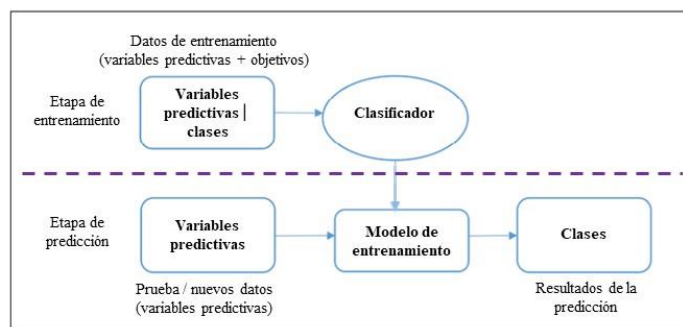


Figura 2-3: Fases del entrenamiento y predicción en clasificación

Nota. Tomado de Liu (2020).

En general existen dos tipos de tareas de clasificación: binaria y multiclase (Mueller & Guido, 2016). La clasificación binaria procura hallar la forma de separar los datos de dos clases como se observa en la Figura 2-4.

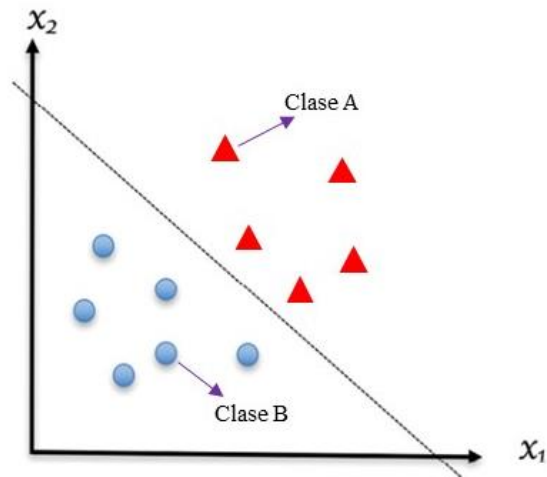


Figura 2-4: Ejemplo de clasificación binaria

Nota. Tomado de Liu (2020). En el gráfico se observa la separación de dos clases, en este caso indicadas por círculos y triángulos.

Los algoritmos o métodos de clasificación más conocidos incluyen: (i) Árboles de decisión; (ii) Naive Bayes; (iii) Análisis discriminante lineal; (iv) K vecinos más cercanos; (v) Redes neuronales; (vi) Máquinas de vectores de soporte (vii) Regresión logística.

Esta investigación se enfoca en la clasificación binaria, en donde la etiqueta Y toma uno de dos valores $\{0, 1\}$. Entonces el problema de la clasificación se centra en usar los datos de entrenamiento $(X_1, Y_1), \dots, (X_n, Y_n) \in X \times \{0, 1\}$ para estimar una función \hat{Y} que, dado un vector de características $x \in X$, genera una etiqueta predicha $\hat{Y}(x) \in \{0, 1\}$ (es decir, la función \hat{Y} "clasifica" x para que sea de clase 0 o de clase 1). La función \hat{Y} se denomina clasificador (Chen y Shah, 2018).

Métodos de clasificación

Las características de los datos y el tamaño del conjunto de datos coadyuban en la selección adecuada del o los algoritmos de aprendizaje automático a emplear. Según Marsland, el algoritmo *Support Vector Machines (SVM)* tiene un rendimiento de clasificación extraordinario en conjuntos de datos de tamaño razonable mientras en conjuntos grandes sucede todo lo contrario (Marsland, 2015). En relación al uso, en la última década, *SVM* es uno de los cuatro algoritmos más utilizados para analizar el

comportamiento de conductores (Elamrani Abou Elasad, Mousannif, Al Moatassime, & Karkouch, 2020); mientras que para resolver problemas basados en evaluación de riesgos por industrias, las técnicas *SVM* y *Decision Trees (DT)* son utilizadas frecuentemente (Hegde & Rokseth, 2020).

Existen diferentes características que contribuyen al uso generalizado de este tipo de clasificadores, entre los cuales se incluyen la interpretabilidad y que no son paramétricos. En el primer caso, brindan evidencia de sus predicciones al mostrar los resultados encontrados; en el segundo caso, hacen pocas suposiciones de modelado sobre los datos y permiten que los datos impulsen las predicciones de manera más directa (Chen y Shah, 2018).

En el presente trabajo nos vamos a concentrar en los algoritmos de clasificación *K-nearest neighbor*, *Support Vector Machines* y *Decision Trees*, debido a que son los más usados en el campo de estudio de los riesgos psicosociales en el sector del transporte terrestre de pasajeros. Otros factores considerados para realizar el modelamiento con estos algoritmos son el tamaño y características del conjunto de datos, así como, la interpretabilidad y que son no paramétricos, en este último caso se considera primordialmente la escala de respuestas del cuestionario utilizado para el levantamiento de información sobre riesgos psicosociales laborales. Estos algoritmos son presentados a continuación.

K-Nearest Neighbors. El clasificador *K nearest neighbor* o *KNN* (K vecinos más cercano) fue propuesto por Fix & Hodges en el año 1951. *KNN* es un algoritmo de clasificación no paramétrico de aprendizaje supervisado basado en instancias que se caracterizan por memorizar el conjunto de datos de entrenamiento (Raschka & Mirjalili, 2017).

A diferencia de otros algoritmos de aprendizaje que permiten descartar los datos de entrenamiento después de que se construye el modelo, *KNN* mantiene todos los ejemplos de entrenamiento en la memoria. El algoritmo se fundamenta en que los puntos de datos cercanos unos con otros son vecinos, por lo tanto, la distancia entre casos es una medida de su diferencia (Figura 2-4).

El algoritmo *KNN* también es llamado como razonamiento basado en casos, aprendizaje basado en instancias o aprendizaje perezoso (Jabbar, Deekshatulu, & Chandra, 2013). *K nearest neighbor* tiene la ventaja de que se adecua inmediatamente

a medida que se compila o incorporan nuevos datos de entrenamiento (Raschka & Mirjalili, 2017).




Figura 2-5: Ejemplo del algoritmo de clasificación K-Nearest Neighbour

Nota. En el gráfico se representan las variables predictoras como cuadrados de color azul (Clase A) y rombos en color rojo (Clase B). La variable para predecir se simboliza con la figura en color verde. En el primer círculo se observan los k vecinos más cercanos cuando es igual a tres y es clasificado con la Clase (A), cuadrado que son 2.

La distancia euclidiana (Ecuación 1) es la forma de calcular la cercanía o similitud entre los puntos de datos (Mosquera, Castrillón, & Parra, 2019).

$$Dist(X_1 X_2) = \sqrt{\sum_{i=1}^d (X_{1i} - X_{2i})^2} \quad (1)$$

Donde:

d = número de descriptores o variables a evaluar.

X_{1i} = valor del descriptor i en la entidad 1.

X_{2i} = valor del descriptor i en la entidad 2.

Seleccionar el valor de K en KNN es el problema más crítico. Un valor pequeño de K significa que el ruido tendrá una mayor influencia en el resultado y tiene la posibilidad de sobreajuste, mientras que un gran valor de K hace que el costo computacional se incremente. El cálculo de K se realiza mediante la técnica de validación cruzada (Saxena, 2016).

Support Vector Machines. *Support Vector Machines* o *SVM* (Máquinas de vectores soporte) es un algoritmo supervisado ampliamente utilizado en clasificación, regresión y estimación de densidad (Al-shargie, Tang, Badruddin, & Kiguchi, 2018) y está basado en la teoría del aprendizaje estadístico propuesto por Vapnik en 1995 (Hasseim,

Sudirman, & Khalid, 2013). El objetivo del algoritmo es encontrar un límite de decisión para separar datos de diferentes clases.

SVM funciona asignando datos a un espacio de características de alta dimensión para que los puntos de datos puedan clasificarse, incluso cuando no sean separables linealmente (Mosquera et al., 2019). Estima un separador para los datos por medio de funciones *kernel*, también conocido como mapeo de datos en un espacio de mayor dimensión. La función matemática usada para la transformación se conoce como función del núcleo y puede ser lineal, polinomial o de base radial.

Los datos se transforman de tal manera que se dibuja un separador como un hiperplano (Figura 2-5). Un hiperplano es un plano de $n - 1$ dimensiones que separa el espacio de características n -dimensional de las observaciones en dos espacios. El hiperplano en un espacio de características bidimensional es una línea, y en un espacio de características tridimensional, es una superficie (Liu, 2020).

El hiperplano óptimo se elige para maximizar la distancia desde sus puntos más cercanos en cada espacio hasta él mismo. Y estos puntos más cercanos son los llamados vectores de soporte.

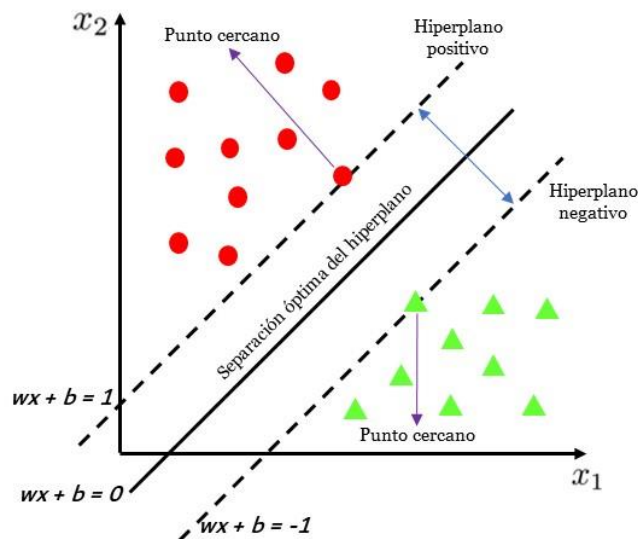


Figura 2-6: Ejemplo del algoritmo de clasificación Máquina de Vectores de Soporte *Nota.* Tomado de Palma y Marín (2008). En el gráfico se observa la separación de dos clases por los hiperplanos, en este caso visualizados por círculos y triángulos.

El rendimiento del algoritmo *SVM* es comparable con redes neuronales y árboles de decisiones (Hegde & Rokseth, 2020). Por lo general *SVM* se usa en clasificación binaria.

Decision Trees. Decision Trees o DT (Árbol de decisión) es un algoritmo de aprendizaje supervisado no paramétrico para tareas de clasificación, regresión y agrupamiento (Palma & Marín, 2008). Tiene como propósito crear un modelo de entrenamiento para predecir la clase o el valor de la variable objetivo en función del aprendizaje de reglas de decisión inferidas de datos del conjunto de entrenamiento. Una variable objetivo con un conjunto discreto de valores o valores continuos determina si es árbol de clasificación o regresión (Saxena, 2016; Shah, 2016).

El algoritmo usa la ganancia de información como criterio para estimar la medida de entropía de cada atributo. La ganancia de información calcula la reducción esperada en la entropía debido a la clasificación del atributo (Saxena, 2016).

Con el propósito de maximizar la obtención de información se dividen los nodos en las características más informativas, requiriendo la definición de una función objetivo que se necesita optimizar mediante el algoritmo de aprendizaje de árboles. Aquí, la función objetivo maximiza la ganancia de información en cada división. Se define como (Ecuación 2):

$$IG(D_p, f) = I(D_p) - \sum_{j=1}^m \frac{N_j}{N_p} I(D_j) \quad (2)$$

Donde, f es la función para realizar la división, D_p y D_j son el conjunto de datos del nodo padre y el j -ésimo hijo, I es la medida de impureza, N_p es el número total de muestras en el nodo principal y N_j es el número de muestras en el j -ésimo hijo nodo. Según Raschka (2017), la ganancia de información es simplemente la diferencia entre la impureza del nodo principal y la suma de las impurezas del nodo secundario, cuanto menor es la impureza de los nodos secundarios, mayor es la ganancia de información (Raschka & Mirjalili, 2017).

La entropía es la cantidad de desorden de información o la cantidad de aleatoriedad en los datos. La entropía en el nodo depende de cuántos datos aleatorios hay en ese nodo y se calcula para cada nodo. En los árboles de decisión, se busca que la entropía sea la más pequeña en sus nodos, debido a que se usa para calcular la homogeneidad de las muestras del nodo. Si las muestras son completamente homogéneas, la entropía es cero y si las muestras se dividen en partes iguales, tiene una entropía de uno.

Un árbol de decisión se representa como un gráfico acíclico que se puede usar para tomar decisiones (Figura 2-7). En cada nodo de ramificación del gráfico, se examina

una característica j específica del vector de características. Si el valor de la característica está por debajo de un umbral específico, se sigue la rama izquierda; de lo contrario, se sigue a la rama derecha. A medida que se llega al nodo hoja, se toma la decisión sobre la clase a la que pertenece.

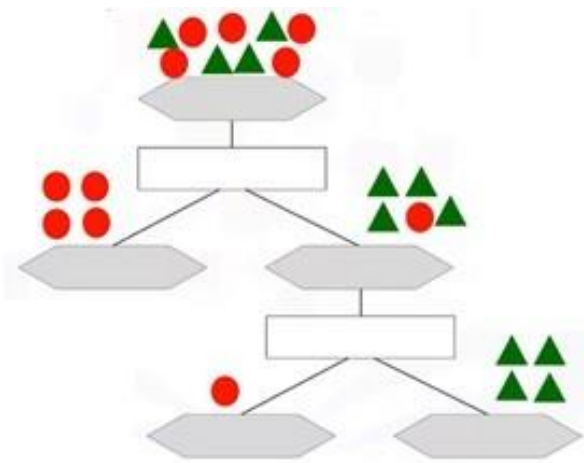


Figura 2-7: Ejemplo del algoritmo de clasificación Árbol de Decisión

Nota. En el rectángulo se ubica el atributo de selección. Las líneas oblicuas representan las ramas del árbol. Los círculos y triángulos simbolizan las clases etiquetadas del conjunto de datos.

Métricas de rendimiento en clasificación

Las métricas de rendimiento explican el desempeño de un modelo (Shi & NGan, 2014). En la literatura especializada se establece que la métricas de rendimiento más apropiadas se fundamentan en la relación entre el número de muestras clasificadas y el número total de muestras (Chicco & Jurman, 2020).

Existen diferentes métricas de evaluación de modelos de clasificación, que incluyen: Matriz de Confusión, Precisión, Sensibilidad, índice Jaccard, F1-score y Área Bajo la Curva.

La matriz de confusión también llamada matriz de clasificación resume las clasificaciones correctas e incorrectas que produjo un clasificador para un determinado conjunto de datos. Las filas y columnas de la matriz corresponden a las clases predichas y verdaderas (actuales), respectivamente. La matriz de confusión en sí misma no es una medida de desempeño para los modelos de clasificación, pero se puede utilizar para calcular varias métricas.

		Predicho	
		Negativo	Positivo
Actual	Negativo	Verdadero Negativo	Falso Positivo
	Positivo	Falso Negativo	Verdadero Positivo

Figura 2-8: Ejemplo de Matriz de Confusión

Nota. La figura enseña el ejemplo de una matriz de confusión para un problema de dos clases (0 y 1).

La *precision* o precisión es también conocida como valor predictivo positivo y se define como el número de predicciones realizadas de forma correcta basadas en la clase positiva. La precisión (Ecuación 3) se calcula con la fórmula:

$$Precision = \frac{Verdaderos\ Positivos}{Verdaderos\ Positivos + Verdaderos\ Negativos} \quad (3)$$

Recall o sensibilidad es también conocido como tasa de aciertos y se define como el número de instancias de la clase positiva que el modelo es capaz de predecir. La fórmula (Ecuación 4) de la sensibilidad es:

$$Sensibilidad = \frac{Verdaderos\ Positivos}{Verdaderos\ Positivos + Falsos\ Negativos} \quad (4)$$

El índice *Jaccard*, también conocido como coeficiente de similitud de Jaccard, se define como el tamaño de la intersección dividido por el tamaño de la unión de dos conjuntos de etiquetas. Toma valores entre 0 y 1, el último valor corresponde a la igualdad total entre los conjuntos objeto de análisis. Su fórmula (Ecuación 5) es:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (5)$$

F1-score o puntaje *F1* es el promedio o media armónica de la precisión y la sensibilidad, que permite optimizar un clasificador para precisión equilibrada y rendimiento de recuperación; donde un puntaje *F1* alcanza su mejor valor en uno (que representa la precisión) y su peor en cero. *F1 score* (Ecuación 6) combina las puntuaciones de *precisión* y *recall* con la fórmula:

$$Puntuación\ F1 = \frac{2 \times (Precisión \times Sensibilidad)}{Precisión + Sensibilidad} \quad (6)$$

Accuracy o precisión general se define como la proporción de predicciones correctas del modelo. La fórmula (Ecuación 7) para su cálculo es:

$$\text{Precisión general} = \frac{VP + VN}{VP + FP + VN + FN} \quad (7)$$

Donde:

VP = Verdaderos Positivos.

VN = Verdaderos Negativos.

FP = Falsos Positivos.

FN = Falsos Negativos.

2.3. Riesgos psicosociales

Un riesgo “es la posibilidad, alta o baja, de que alguien sufra un daño causado por un peligro” (EU-OSHA, 2010). Mientras que el riesgo laboral “es la probabilidad de que la exposición a un factor ambiental peligroso en el trabajo cause enfermedad o lesión” (Consejo Andino de Ministros de Relaciones Exteriores, 2018).

Cuando las condiciones laborales en las que están inmersos los trabajadores no son las más adecuadas, se configuran los denominados riesgos psicosociales laborales, y la consecuencia lógica es una alta probabilidad de deterioro de la salud (Bravo & Nazar, 2015). Esta realidad no es ajena a los conductores de buses urbanos, quienes presentan una mayor prevalencia de enfermedades laborales como trastornos del sueño, problemas cardiovasculares, problemas musculoesqueléticos, fatiga y sintomatología ansioso-depresiva (Chaparro & Guerrero, 2001; Instituto Nacional de Seguridad e Higiene en el Trabajo, 2015; Schneider & Irastorza, 2011).

La Agencia Europea para la Seguridad y Salud en el Trabajo, desde hace varios años, ha planteado la existencia de riesgos nuevos y emergentes, y los ha definido como “cualquier riesgo nuevo que va en aumento”, con las siguientes distinciones: “nuevo” significa que el riesgo no existía anteriormente y es el resultado de aplicar procesos modernos, tecnologías recientes o cambios sociales. Mientras que el riesgo “va en aumento” cuando aumenta la cantidad de peligros que dan lugar al mismo o el efecto del peligro sobre la salud del trabajador se agrava (Brocal, 2014; Schneider & Irastorza, 2011).

Hay diversas investigaciones que identifican la existencia de varios modelos teóricos que establecen la relación entre los riesgos psicosociales y la salud: el Modelo Demanda-Control de Karasek, el Modelo del Desequilibrio Esfuerzo Recompensa de Siegrist y recientemente el concepto de Justicia Organizacional de Elovainio, que

tienen el suficiente marco teórico para apoyar esta relación. Cabe decir que los modelos citados no son mutuamente excluyentes sino complementarios (Vega, 2001; Elovainio, Kivimäki, & Vahtera, 2002; Luceño, Martín, Jaén, & Díaz, 2005; Moreno & Baez, 2010; Moreno Jiménez, 2012; Eurofound and EU-OSHA, 2014).

También se ha planteado la conexión entre salud psicosocial y la gestión en la organización (Ivancevich & Matteson, 1980; Ivancevich, Matteson, Freedman, & Phillips, 1990; Salanova & Llorens, 2008). Según Frutos, los modelos de Karasek y Siegrist se relacionan con el Modelo de Estrés Orientado a la Dirección de Ivancevich y Matteson, que se caracteriza por estudiar los estresores vinculados con el liderazgo, estructura y control organizacional, recompensas, factores intrínsecos al puesto de trabajo, y desarrollo de carrera (Frutos, 2014).

Para Leka (2016) los factores de riesgo psicosocial deben ser abordados en el lugar de trabajo, en donde los empleadores consideran que están relacionados con la carga de trabajo, horarios de trabajo, claridad de roles, comunicación, recompensas, trabajo en equipo, resolución de problemas y relaciones en el trabajo. En la literatura sobre gestión estratégica y gestión de recursos humanos se observa que los estresores están relacionados con los procesos de dirección y recursos humanos (Mintzberg, 2011; Gómez-Mejía, Balkin & Cardy, 2016). Adicionalmente, en otros estudios se plantea que la fuente del estrés laboral no es exclusiva del trabajador o de sus interrelaciones con otros trabajadores, sino que son generadas por la organización, sus exigencias y los limitados recursos que dispone (Peiro & Rodríguez-Molina, 2008; Salanova & Llorens, 2008).

Agregando a lo anterior, el Modelo Demanda-Control de Karasek, y el Modelo del Desequilibrio Esfuerzo Recompensa de Siegrist aportan los elementos teóricos para el desarrollo de instrumentos que posibilitan la evaluación de los referidos riesgos, entre los que se incluyen: el Cuestionario de Evaluación de Riesgos Psicosociales del Instituto Navarro de Salud Laboral; el Cuestionario Multidimensional para la Evaluación de Factores Psicosociales en el Entorno Laboral de la Universidad Complutense de Madrid; el Método de Evaluación de Factores Psicosociales FPSICO del Instituto Nacional de Seguridad e Higiene en el Trabajo (Luceño et al., 2005).

CAPÍTULO III

MARCO METODOLÓGICO

3.1. Metodología

Introducción

A lo largo de la historia de la ciencia han surgido diversas corrientes de pensamiento y distintos marcos interpretativos que han abierto las rutas para la búsqueda del conocimiento (Hernández, 2014); así como, una significativa variedad de métodos de investigación científica (Bernal, 2010), entre los cuales está la investigación de diseño. Para Roworth-Stokes (2011) y Vaishnavi & Kuechler (2008), citado por Carstensen & Bernhard (2018), la investigación de diseño se estableció como un campo de estudio en 1966, cuando se fundó la "*Design Research Society*"; siendo su objetivo principal desarrollar una teoría para el proceso o fenómeno del diseño de objetos y artefactos exitosos hechos por el hombre, tales como: constructos, modelos, métodos e instancias. Así, en ciencias del diseño, la comprensión y la solución a un problema es obtenida mediante el diseño e implementación de un artefacto (Hevner y Chatterjee, 2010).

El presente estudio, enfocado en elaborar un modelo predictor basado en aprendizaje automático capaz de realizar un pronóstico en el ámbito de los riesgos psicosociales laborales en el sector del transporte urbano, se adapta a una investigación de este tipo.

Metodología de investigación en ciencias del diseño en sistemas de información

Hevner y Chatterjee (2010), citado por Brahma (2019), explican que el Diseño en Sistemas de Información (*DSR* por sus siglas en inglés) es un proceso iterativo que incluye fases de ciclo de relevancia, ciclo de rigor y ciclo de diseño. Las actividades de construcción y evaluación continuas e iterativas en el ciclo de diseño marcan una de las características significativas de la metodología *DSR*.

La metodología de investigación científica del diseño (conocido por su acrónimo *DSRM*) incorpora los principios, prácticas y procedimientos necesarios para llevar a cabo la investigación de Ciencias del Diseño en *IS* (Peffer, 2007).

Metodología para el desarrollo de proyectos en minería de datos CRISP-DM

Según Peffer (2007) no hay una metodología que sirva de marco comúnmente aceptado para la investigación de *DS* en *IS* y desde hace varios años se han desarrollado

diversos modelos que son compatibles con *DSRM*. Uno de ellos, usado en el contexto de la analítica de datos, es el modelo *Cross Industry Standard Process for Data Mining* (*CRISP-DM*, por sus siglas en inglés) que tiene sus orígenes en el año 1999, que es un modelo de proceso estándar de la industria usado para proyectos de minería de datos. *CRISP-DM* describe los pasos, procesos y flujos de trabajo requeridos en la ejecución de proyectos, desde los requisitos iniciales hasta la implementación de soluciones para transformar los datos en conocimientos (Sarkar et al., 2018). Está conformado por seis fases (Figura 3-1):




Figura 3-1: Fases del modelo Cross Industry Standard Process for Data Mining
Nota. Tomado de Sarkar, Bali y Sharma (2018). Ciclo del modelo CRISP-DM.

Fase de comprensión del problema. Considera las etapas de comprensión de objetivos y requisitos del proyecto desde una perspectiva organizacional, con el propósito de lograr la transformación a objetivos técnicos y plan de proyecto.

Fase de comprensión de datos. Involucra la recolección inicial de datos, a fin de establecer un primer contacto con el problema, su familiarización, identificar su calidad y establecer las relaciones para definir las primeras hipótesis.

Fase de preparación de datos. Adecúa los datos para su empleo en las técnicas de *Data Mining* que se usen posteriormente, tales como: visualización de datos, búsqueda de relaciones entre variables u otras medidas para explorar datos.

Fase de modelado. En base a criterios, se seleccionan las técnicas de modelado más apropiadas para el proyecto de *Data Mining*.

Fase de evaluación. Se consideran los criterios de éxito del problema. De ser el caso se repite alguna etapa anterior en donde se haya cometido errores. Las matrices de confusión son muy empleadas en problemas de clasificación.

Fase de implantación. Una vez que el modelo ha sido construido y validado, se transforma el conocimiento obtenido en acciones dentro del proceso de negocio.

El levantamiento inicial de datos en el ámbito de los riesgos psicosociales laborales requiere la aplicación de un instrumento técnico que implica el uso de una metodología especialmente desarrollada para la identificación y evaluación de los mencionados riesgos, y sobre todo aceptada en el campo de la seguridad y salud en el trabajo. Por lo tanto, se considera necesario para las fases de comprensión del problema y de datos que la recolección, análisis y evaluación de riesgos psicosociales se efectúe con el método del INSHT de España. Si bien existen varias metodologías para el efecto, se ha seleccionado la del INSHT por las facilidades del software disponible y menor tiempo de aplicación de las encuestas.

Metodología para la identificación, análisis y evaluación de riesgos psicosociales del INSHT de España

El proceso para la identificación, análisis y evaluación de riesgos psicosociales (Figura 3-2) consta de tres fases y seis etapas (Instituto Nacional de Seguridad e Higiene en el Trabajo, 2015):




Figura 3-2: Fases del modelo de evaluación de factores psicosociales

Nota. Tomado del INSHT de España (2015).

Etapa de identificación de factores de riesgo. En esta etapa se define de forma precisa el factor o factores que se deben investigar y sus diferentes aspectos o facetas.

Etapa de elección de la metodología, técnicas e instrumentos que se aplican. Se analiza y compara los diversos métodos, técnicas e instrumentos teniendo en cuenta ventajas y desventajas. Es frecuente el uso de varios métodos, técnicas y / o instrumentos, siendo la combinación de información de tipo cuantitativo y cualitativo la elección más adecuada.

Etapa de planificación y realización del trabajo de campo. Es imprescindible prever los aspectos prácticos del trabajo de campo y haber informado previamente a las personas implicadas tanto de estos aspectos como del objetivo que se persigue.

Etapa de análisis de resultados y elaboración del informe. Esta etapa debe permitir encontrar la causa o causas del problema o problemas detectados al examinar los resultados obtenidos. En la determinación de estas causas hay que tratar de identificar las causas “reales” y no sólo las “aparentes”. Se debe proceder a una valoración de los riesgos

Etapa de elaboración y puesta en marcha del programa de intervención. Con los resultados obtenidos se desarrolla el plan de intervención a medida, con soluciones específicas, las cuales deben ser elaboradas con la participación de las partes involucradas en el estudio, con la finalidad de incrementar las probabilidades de éxito.

Etapa de seguimiento y control de las medidas adoptadas. Conlleva la realización de varias evaluaciones para comprobar la evolución del programa de intervención. En la aplicación de esta etapa es menester dejar pasar un periodo de tiempo adecuado, con el propósito de verificar que las medidas adoptadas están surtiendo el efecto deseado. Las etapas de elaboración y puesta en marcha del programa, así como de seguimiento y control de medidas adoptadas forman parte de lo que se denomina intervención psicosocial y evaluación de la eficacia de las medidas de intervención, y no forman parte del desarrollo de la presente investigación debido al tiempo que conlleva su aplicación y que supera ampliamente al plazo establecido para la presentación de la tesis.

3.2. Hipótesis

El empleo de técnicas de aprendizaje automático permite predecir con una precisión aceptable los riesgos psicosociales en el sector del transporte terrestre urbano.

3.3. Población y muestra

Los participantes en el estudio del cual se obtuvieron los datos fueron 341 conductores de autobuses de transporte urbano de la ciudad de Ambato, pertenecientes a cuatro cooperativas. A ellos se les aplicó el cuestionario Fpsico 4.0, versión corta, que contiene 89 ítems.

Los criterios de inclusión del estudio fueron:

- (i) Participación voluntaria en el estudio;
- (ii) Contrato de operación para prestar servicio de transporte público de personas en vigencia;
- (iii) Ámbito de operación intracantonal; y,
- (iv) Que los conductores tengan al menos un año de trabajo en la cooperativa de la que forman parte.

El procedimiento para conocer con cierta precisión cuántos registros se necesitaban para lograr un determinado grado de confiabilidad con el conjunto de datos se estableció según la regla de Delmaster y Hancock (2001). Para este autor, el conjunto de datos debería tener al menos $6 \times m \times p$ registros, donde m es el número de clases de resultado y p es el número de variables (Shmueli, Bruce, Gedeck, & Patel, 2020).

Reemplazando los valores en la fórmula se obtiene un resultado de 276 registros mínimos requeridos para el modelamiento con los algoritmos planteados. El tamaño del conjunto de datos en la presente investigación es de 341 registros.

No se calculó la muestra y por consiguiente los cuestionarios se aplicaron a toda la población (Meliá *et al.*, 2006), durante el segundo semestre del 2019.

3.4. Descripción de instrumentos utilizados

El cuestionario autoadministrado seleccionado fue el Fpsico 4.0, versión corta, diseñado para organizaciones de cualquier tamaño y ámbito, que contiene 44 preguntas, algunas de ellas múltiples, de manera que el número total de ítems llegó a 89 ítems.

Las dimensiones de estudio son nueve e incluyen “Tiempo de trabajo (TT), Autonomía (AU), Carga de trabajo (CT), Demandas psicológicas (DP), Variedad/Contenido (VC), Participación/Supervisión (PS), Interés por el trabajador/Compensación (ITC), Desempeño de rol (DR) y Relaciones y apoyo social (RAS)” (Pérez Bilbao & Nogareda Cuixart, 2012).

Al cuestionario se adicionaron preguntas de antecedentes sociodemográficos, laborales y de siniestralidad que sumaron 15 preguntas, con lo cual se alcanzó un total de 104 preguntas, con escalas de respuesta dicotómica y Likert de 5 puntos (Anexo 1). El tiempo estimado de aplicación por cuestionario fue de 25 a 30 minutos y se aplicaron en los terminales de las cooperativas. Una vez recopilados los datos se ingresaron en el software del FPsico 4.0.

A fin de cumplir con lo señalado en el Ministerio de Trabajo del Ecuador se verificó que el instrumento tenga validez y fiabilidad nacional o internacional. El instrumento tiene un Alpha de Cronbach de 0.895 (Ferrer, Guilera, & Perú, 2011), catalogado como Excelente (≥ 0.85).

La verificación de adecuación del lenguaje a determinadas preguntas del cuestionario se realizó mediante una entrevista cognitiva a cinco conductores tomados de forma aleatoria de las cooperativas participantes en el estudio. A partir de allí, se estableció que las preguntas no requerían modificación alguna.

De forma complementaria se aplicó a la población objeto de estudio el cuestionario de Auto-reporte o *Self-Reporting Questionnaire (SRQ-20)*, que consta de 30 preguntas con escala de respuestas de tipo dicotómico, las primeras 20 preguntas se refieren a síntomas ansioso/depresivos, preguntas 21 a 24 psicosis, pregunta 25 síndrome convulsivo epilepsia; y, preguntas 26 a 30 alcoholismo. El tiempo estimado para llenar este cuestionario autoadministrado fue de 10 minutos aproximadamente. El software empleado para el procesamiento de la información fue el *SPSS V 22*.

Los datos relacionados con el número de unidades que brindan el servicio de transporte urbano y el número de accidentes clasificados por causas y tipos se obtuvieron de la base de datos de la Agencia Nacional de Tránsito del Ecuador (ANT).

3.5. Operacionalización de variables

3.5.1. Definición y operacionalización de riesgos psicosociales laborales

Los riesgos psicosociales se definen como aquellos que “se derivan de las deficiencias en el diseño, la organización y la gestión del trabajo, así como de un escaso contexto social del trabajo, y pueden producir resultados psicológicos, físicos y sociales negativos, como el estrés laboral, el agotamiento o la depresión” (EU-OSHA, 2010). Las dimensiones de estudio consideradas son las del modelo del Instituto Nacional de Seguridad e Higiene en el Trabajo español (Tabla 3-1).

**Tabla 3-1: DIMENSIONES DE LA VARIABLE RIESGOS PSICOSOCIALES
LABORALES**

Dimensiones	Definición conceptual	Ítem
Tiempo de trabajo	“Aspectos relacionados con la ordenación y estructura temporal de la actividad laboral de cada día de la semana”.	1, 2, 5, 6.
Autonomía	“Es la capacidad y posibilidad individual del trabajador para gestionar y tomar decisiones sobre procedimientos y organización del trabajo”.	3, 7, 8, 9, 10a, 10b, 10c, 10d, 10e, 10f, 10g, 10h.
Carga de trabajo	“Es el nivel de demanda de trabajo a la que el trabajador ha de hacer frente”.	23, 24, 25, 21, 22, 27, 30, 31, 32, 26, 28, 29, 4.
Demandas psicológicas	“Es la naturaleza de las distintas exigencias a las que se ha de hacer frente en el trabajo, pueden ser cognitivas y emocionales”.	33a, 33b, 33c, 33d, 33e, 33f, 34a, 34b, 34c, 34d, 35, 36.
Variedad/Contenido	“Es la sensación de que el trabajo tiene un significado y utilidad en sí mismo, para el trabajador, en el conjunto de la empresa y para la sociedad en general”.	37, 38, 39, 40a, 40b, 40c, 40d.
Participación/Supervisión	“Es la valoración que el trabajador hace del nivel de control que sus superiores inmediatos ejercen sobre la ejecución del trabajo”.	11a, 11b, 11c, 11d, 11e, 11f, 11g, 12a, 12b, 12c, 12d.
Interés por el trabajador/Compensación	“Grado en que la empresa muestra una preocupación de carácter personal y a largo plazo por el trabajador”.	13a, 13b, 13c, 13d, 41, 42, 43, 44.
Desempeño de rol	“Problemas que pueden derivarse de la definición de los cometidos de cada puesto de trabajo, comprende la ambigüedad y conflicto de rol”.	14a, 14b, 14c, 14d, 14e, 14f, 15a, 15b, 15c, 15d, 15e.
Relaciones y apoyo social	“Son aquellos aspectos de las condiciones de trabajo que se derivan de las relaciones que se establecen entre las personas en los entornos de trabajo”.	16a, 16b, 16c, 16d, 17, 18a, 18b, 18c, 18d, 19, 20.

Nota. Tomado del INSHT (2014). Los ítems están agrupados por dimensión.

3.6. Diseño de la investigación basado en la metodología *CRISP-DM*

En esta sección, explicamos detalladamente la aplicación de la metodología *CRISP-DM* a nuestro problema específico.

Fase 1: Comprender el problema

El dilema al que conllevan los riesgos psicosociales laborales se plasma en el estrés laboral y en las consecuencias de índole social y económico para los conductores, las cooperativas de transporte, los usuarios y el país. El propósito del presente estudio es identificar, analizar y predecir de forma anticipada este tipo de riesgos para una oportuna toma de decisiones.

Fase 2: Comprender los datos

La comprensión de datos involucra la recolección, descripción, exploración y verificación de la calidad de datos. Cada una de estas etapas se explican a continuación:

Etapas de recolección de datos iniciales. La obtención de datos preliminares se efectuó mediante la aplicación de los cuestionarios: (i) Fpsico 4.0 en el cual se incluyeron preguntas sociodemográficas y laborales; (ii) Auto-reporte o *Self-Reporting Questionnaire (SRQ-20)* para diagnóstico de ansiedad; y, (iii) Organización y gestión de riesgos psicosociales.

Los datos relacionados con el número de unidades que dan el servicio de transporte urbano; así como, el número de accidentes clasificados por causas y tipos se obtuvieron de la base de datos de la Agencia Nacional de Tránsito del Ecuador (ANT).

Los cuestionarios fueron aplicados de forma individual por los estudiantes de la Escuela de Psicología Industrial de la UTA, durante el año 2019.

Etapas de descripción de datos. El procesamiento de los cuestionarios de riesgos psicosociales, incluidos los datos sociodemográficos y laborales, serán ingresados en el software Fpsico 4.0; mientras que los cuestionarios del *SRQ-20*, de la organización y gestión de riesgos psicosociales se procesarán en el *SPSS V22*. Los datos de la ANT se procesarán en Excel.

En esta etapa inicial los resultados se visualizarán en tablas y gráficos. El análisis de confiabilidad se efectuará a través del Alpha de Cronbach que también se realizará con SPSS.

Etapas de exploración de datos. Con los datos obtenidos se construirá el conjunto de datos o *dataset*. El lenguaje de programación que se empleará en la exploración de datos y posteriores etapas del estudio es *Python V 3.8.5*. Se analizará el formato de datos y se identificarán datos perdidos. De igual manera, se examinarán las medidas

de tendencia central y dispersión correspondientes; además, se crearán tablas de frecuencia y se construirán gráficos de distribución.

Etapa de verificación de la calidad de datos. A través de análisis de valores atípicos, valores mínimos y máximos, tratamiento de valores ausentes y asociación entre variables discretas se examinará la calidad de datos.

Fase 3: Preparación de datos

Etapa de selección de datos. Mediante la correlación de Spearman se identificará la asociación entre variables y se identificarán las posibles variables predictoras.

Etapa de limpieza de datos. En las variables predictoras se identificarán las que son binarias, categóricas y ordinales, y numéricas, las que serán codificadas según corresponda. A continuación, se realizará el escalamiento de estas variables y la discretización de la variable objetivo o dicotomización.

Etapa de estructura e integración de datos. No se prevé la generación de nuevos atributos a partir de atributos ya existentes o integrar nuevos registros. Tampoco se prevé generar nuevos campos a partir de otros existentes o crear nuevos registros.

Etapa de formateo de datos. Está previsto reordenar registros de la tabla y el ajuste de los valores de los campos a las características del software Python como la eliminación de punto y comas, y caracteres especiales.

Fase 4: Modelamiento

Etapa de selección de la técnica de modelamiento. En AA supervisado hay algoritmos de regresión y clasificación. En regresión el objetivo es predecir un número continuo mientras que en clasificación el propósito es predecir una etiqueta de clase. La variable objetivo del presente conjunto de datos está en función del nivel de estrés y es una etiqueta de clase; en consecuencia, se utilizarán algoritmos de clasificación. Otro parámetro que se considera en la elección del algoritmo es el tamaño del conjunto de datos; por ejemplo, SVM tiene un bajo rendimiento de clasificación en conjuntos de datos de tamaño grande mientras en tamaños razonables sucede todo lo contrario (Marsland, 2015).

También se considera como criterio de selección la frecuencia de uso del algoritmo; por ejemplo, en la última década, SVM es uno de los cuatro algoritmos más empleados en el análisis del comportamiento de conductores. De igual forma, en la resolución de

problemas basados en evaluación de riesgos por industrias, las técnicas SVM y DT se usan constantemente. Finalmente, el algoritmo KNN se utiliza asiduamente para probar conjuntos de datos en AA supervisado y a partir de este, usar otros algoritmos (Elamrani Abou El Assad et al., 2020; Hegde & Rokseth, 2020).

Por las razones expuestas anteriormente, en el presente estudio se aplicarán los algoritmos *KNN*, *SVM* y *DT*.

Etapas de generación del plan de prueba. La clasificación se basa en un conjunto de entrenamiento etiquetado que permite aprender un conjunto de parámetros del modelo, posteriormente este modelo se aplica a datos sin etiquetar con el objeto de predecir la clase a la que pertenece cada instancia.

En la calidad y validez del modelo de clasificación supervisado es común el uso de la razón de error como medida de la calidad; para este efecto, es necesario separar los datos en dos conjuntos, uno de entrenamiento y otro de prueba, para luego construir el modelo basado en el conjunto de entrenamiento y medir la calidad del modelo generado con el conjunto de prueba. El conjunto de entrenamiento contará con el 80% de los datos y el de prueba con el 20%.

Etapas de construcción del modelo. En los tres modelos se aplicará el mismo conjunto de datos y la división de entrenamiento con el 80% y prueba del 20%.

En el modelo *KNN* se calculará primero el valor de *k*-vecinos. A continuación, se examinará la precisión, sensibilidad y el índice *f1*, después se construirá la matriz de confusión y, finalmente, se hará la predicción.

En el modelo *SVM* se examinará la asociación entre variables usando el estadístico de Spearman. A continuación, se ajustará el modelo, se realizará la predicción, después se examinará la precisión, sensibilidad y el índice *f1*; finalmente, se construirá la matriz de confusión

En cuanto al modelo *DT*, se ajustará el modelo, después se identificará el número de niveles y de nodos, luego se realizará la predicción. Posteriormente se examinará la precisión, sensibilidad y el índice *f1*, después se construirá la matriz de confusión; y, finalmente se elaborará el Árbol de Decisión.

Etapas de evaluación del modelo. La evaluación de los modelos *KNN*, *SVM* y *DT* se realizará a través de los índices “*precision*”, “*recall*” y “*f1-score*” para cada uno de los conjuntos “sin estrés” y “con estrés”.

Fase 5: Evaluación

Etapas de evaluación de resultados. La evaluación de los modelos *KNN*, *SVM* y *DT* se realizará con los índices Jaccard y F1-score. Esta evaluación también involucra la relación con los objetivos del estudio y trata de determinar si hay alguna razón que contribuya a que uno de los modelos sea deficiente.

Etapas de revisión y determinación de futuras fases. Estas dos etapas no están consideradas dentro del alcance del presente estudio.

Fase 6: Implantación

Esta fase no está considerada dentro del alcance de la investigación que se realiza.

En resumen, en la investigación se han usado dos metodologías de investigación que se han acoplado de forma apropiada: el modelo de riesgos psicosociales del INSHT y el método *CRISP-DM*.

3.7. Aspectos éticos

Los consentimientos informados se aplicaron de forma individual a los conductores y durante la socialización se dio a conocer el propósito del estudio, el manejo seguro y confidencial de los datos, así como el uso con fines académicos.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1 Resultados de la fase de comprensión de datos

Resultados socio demográficos

Tabla 4-1: CARACTERÍSTICAS SOCIODEMOGRÁFICAS DE LA POBLACIÓN

Variable	Escalas de respuesta	N	%
Sexo	Mujer	0	0
	Hombre	341	100
Edad	18 a 30 años	58	17.00
	31 a 40 años	105	30.79
	41 a 50 años	119	34.90
	51 a 65 años	54	15.84
	Más de 65 años	5	1.47
Nivel de educación	Básica	121	35.48
	Bachiller	181	53.08
	Tercer nivel	39	11.44
Labora únicamente como conductor	Si	318	93.26
	No	23	6.74
Es propietario de la unidad que conduce	Si	124	36.36
	No	217	63.64
Años de experiencia como conductor de bus	De 1 a 4 años	56	16.42
	De 5 a 9 años	76	22.29
	De 10 a 19 años	116	34.02
	Más de 20 años	93	27.27
Afiliación al IESS	Si	163	47.80
	No	178	52.20

Análisis de resultados

En la tabla 4-1 se presentan las características sociodemográficas de la población que intervino en el estudio.

Participaron 341 conductores, de los cuales el 100% son hombres, con edades comprendidas mayoritariamente entre 41 y 50 años (34.9%); el 53% son bachilleres; el 93.26% trabaja exclusivamente como conductor; el 39.36% son propietarios de los buses; el 34% tiene experiencia entre 10 y 19 años; y, el 47.80% es afiliado al seguro social ecuatoriano.

Resultados de riesgos psicosociales laborales

Tabla 4-2: PREVALENCIA DE EXPOSICIÓN A RIESGO PSICOSOCIAL

Dimensión	Adecuado	Moderado	Elevado	Muy elevado
Tiempo de trabajo	108	72	52	109
Autonomía	203	50	39	49
Carga de trabajo	166	40	45	90
Demanda psicológica	147	59	48	87
Variedad / Contenido	253	34	26	28
Participación / Supervisión	73	40	60	168
Interés por trabajador/Compensación	307	15	13	6
Desempeño de rol	190	34	30	87
Relaciones y apoyo social	161	38	55	87




Figura 4-1: Mapa de riesgos psicosociales de la UCTUT

Análisis de resultados

En la Tabla 4-2 se identifica la cantidad de encuestados clasificados por nivel de riesgo y dimensión.

En la Figura 4-1 se observa el mapa de calor de riesgos psicosociales, en donde la situación desfavorable se determina por los valores cercanos, iguales o superiores a la media y que son el resultado de la suma de los riesgos elevados y muy elevados en cada dimensión, hallándose en esta situación el factor Participación / Supervisión con el 66.9%, y los factores Tiempo de Trabajo (47.2%) y Relaciones y Apoyo Social (41.1%). Por otro lado, y en condiciones favorables (suma de riesgo moderado y situación adecuada), están los restantes factores o dimensiones de riesgos psicosociales.

Resultados de accidentabilidad y siniestralidad

Tabla 4-3: INFRACCIONES DE TRÁNSITO DEL PERIODO 2017 - 2018

Cooperativas de transporte urbano	Número de unidades	Infracciones Periodo 2017 - 2018	%
Cooperativa 1	144	91	54.49
Cooperativa 2	45	12	7.19
Cooperativa 3	87	40	23.95
Cooperativa 4	65	24	14.37
Total	341	167	100

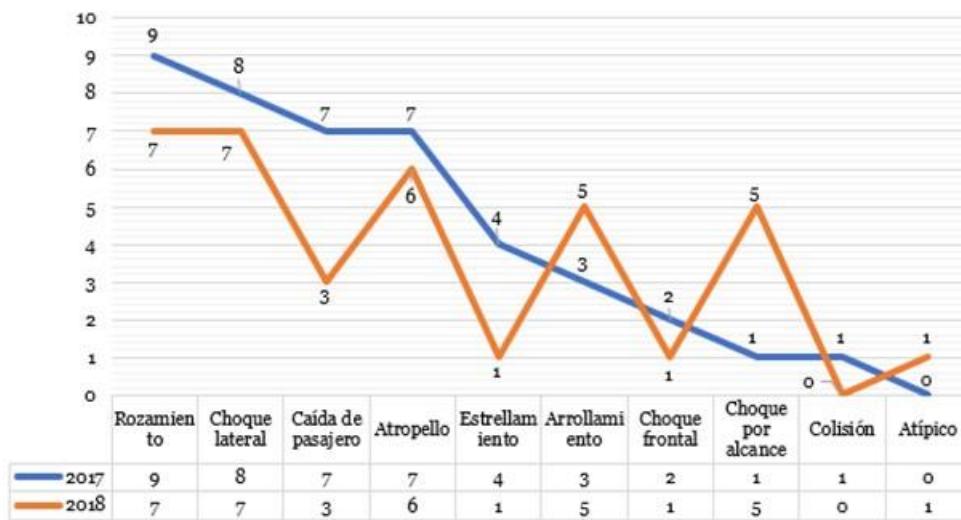


Figura 4-2: Siniestros de tránsito periodo 2017 - 2018

Análisis de resultados

En la Tabla 4-3 se observa que las infracciones de tránsito cometidas por los conductores de la Cooperativa 1 es la que presenta la mayor tasa, mientras que la de menor tasa es la cooperativa 2.

Por otro lado, de la Figura 4-2 se desprende que hay un decremento del 14.2% en el nivel de siniestralidad en el periodo de análisis. En el 2017 hubo 42 siniestros, mientras que en el 2018 fueron 36. Los arrollamientos y choques por alcance tuvieron incrementos significativos en el 2018 con relación al 2017.

Resultados gestión de riesgos

Tabla 4-4: ORGANIZACIÓN Y GESTIÓN DE RIESGOS PSICOSOCIALES

Variable	Escala de respuesta	N	%
Dispone de unidad de gestión de riesgos	Si	0	0
	No	341	100
Dispone de un delegado de SST.	Si	0	0
	No	341	100
Dispone de un protocolo para tratar el estrés	Si	0	0
	No	341	100
Dispone de un protocolo para tratar el acoso laboral	Si	0	0
	No	341	100
Dispone de un procedimiento para tratar los RP	Si	0	0
	No	341	100
Se aplican los procedimientos de gestión de RH	Nunca	137	40.2
	Ocasionalmente	134	39.3
	Frecuentemente	58	17
	Siempre	12	3.5
Los problemas de SST se tratan en reuniones de alto nivel	Nunca	242	71
	Ocasionalmente	70	20.5
	Frecuentemente	19	5.6
	Siempre	10	2.9

Análisis de resultados

Los resultados mostrados en la Tabla 4-4 destacan el hecho que las operadoras no relacionan el liderazgo y compromiso de la Dirección con el sistema de gestión de riesgos.

Resultados de fiabilidad del instrumento

Tabla 4-5: FIABILIDAD DEL INSTRUMENTO

Resumen del procesamiento de los casos

		N	%
Casos	Válidos	341	100,0
	Excluidos ^a	0	,0
	Total	341	100,0

a. Eliminación por lista basada en todas las variables del procedimiento.

Estadísticos de fiabilidad

Alfa de Cronbach	Alfa de Cronbach basada en los elementos tipificados	N de elementos
,843	,839	89

Análisis de resultados

El indicador de la fiabilidad como consistencia interna del instrumento se obtiene con el Alpha de Cronbach con un valor de 0.843, que es catalogado como Bueno, de acuerdo con el rango $0.80 \leq r \leq 0.85$ (Tabla 4-5). Este valor es cercano al Alpha de Cronbach de validación del instrumento que fue de 0.895 (Ferrer et al., 2011), catalogado como Excelente (≥ 0.85).

Resultados de datos perdidos y formato de datos

Tabla 4-6: FORMATO DE DATOS E IDENTIFICACIÓN DE DATOS PERDIDOS

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 341 entries, 0 to 340
Columns: 123 entries, sexo to strestot
dtypes: int64(113), object(10)
memory usage: 327.8+ KB
```

	sexo	ecivil	edad	cfam	nedu	exp	...	P.28	P.29	P.30	P.31	P.32	P.4	resct	stresct	total	strestot
0	False	False	False	False	False	False	...	False	False	False	False	False	False	False	False	False	False
1	False	False	False	False	False	False	...	False	False	False	False	False	False	False	False	False	False
2	False	False	False	False	False	False	...	False	False	False	False	False	False	False	False	False	False
3	False	False	False	False	False	False	...	False	False	False	False	False	False	False	False	False	False
4	False	False	False	False	False	False	...	False	False	False	False	False	False	False	False	False	False

Análisis de resultados

En la tabla 4-6 se observa que el conjunto de datos tiene 341 filas y 123 columnas. Los datos son de tipo “entero” y “objeto”. No hay datos perdidos y consecuentemente no se realiza tratamiento alguno para este problema. En el análisis se utilizó la librería Pandas de Python.

Resultados de codificación de datos

Tabla 4-7: CODIFICACIÓN DE VARIABLES

	sexo	ecivil	edad	cfam	nedu	exp	rdinero	averbal	afisica	depre	...	P.28	P.29	P.30	P.31	P.32	P.4	resct	stresct	total	strestot
0	1	2	1	1	3	3	2	1	2	0	...	3	4	3	1	4	2	33	no	196	no
1	1	4	3	2	2	2	2	2	2	0	...	3	4	3	3	2	2	35	no	229	no
2	1	2	5	2	1	4	0	1	0	0	...	3	3	1	4	4	1	35	no	211	no
3	1	1	4	2	1	2	0	1	0	0	...	3	3	2	3	3	2	39	no	218	no
4	1	1	1	1	3	1	2	3	3	0	...	3	3	4	2	3	2	36	no	215	no

```

sexo      int64
ecivil    int64
edad      int64
cfam      int64
nedu      int64
...
P.4       int64
resct     int64
stresct   object
total     int64
strestot  object
Length: 123, dtype: object

```

	sexo	ecivil	edad	cfam	nedu	exp	rdinero	averbal	afisica	depre	...	P.28	P.29	P.30	P.31	P.32	P.4	resct	stresct	total	strestot
0	1	2	1	1	3	3	2	1	2	0	...	3	4	3	1	4	2	33	0	196	0
1	1	4	3	2	2	2	2	2	2	0	...	3	4	3	3	2	2	35	0	229	0
2	1	2	5	2	1	4	0	1	0	0	...	3	3	1	4	4	1	35	0	211	0
3	1	1	4	2	1	2	0	1	0	0	...	3	3	2	3	3	2	39	0	218	0
4	1	1	1	1	3	1	2	3	3	0	...	3	3	4	2	3	2	36	0	215	0

```

sexo      int64
ecivil    int64
edad      int64
cfam      int64
nedu      int64
...
P.4       int64
resct     int64
stresct   int64
total     int64
strestot  int64
Length: 123, dtype: object

```

Análisis de resultados

La Tabla 4-7 presenta el conjunto de datos inicial, existen variables de tipo numérico, categóricas y ordinales, identificadas como “int64” y “objeto”. Con el tratamiento de datos todas las de tipo “objeto” fueron transformadas a “int64”. Las variables con respuestas binarias “no” y “si” fueron codificadas como 0 y 1, respectivamente.

4.2 Resultados de la fase de preparación de datos

Resultados de la estructura del conjunto de datos

Tabla 4-8: DESCRIPCIÓN DEL CONJUNTO DE DATOS

Dimensiones	Variables
Sociodemográficas	"sexo", "ecivil", "edad", "cfamr", "nedu", "exp", "rdinero", "averbal", "afisica", "depre".
Tiempo de Trabajo	"P.1", "P.2", "P.5", "P.6".
Autonomía	"P.3", "P.7", "P.8", "P.9", "P.10a", "P.10b", "P.10c", "P.10d", "P.10e", "P.10f", "P.10g", "P.10h".
Carga de Trabajo	"P.23", "P.24", "P.25", "P.21", "P.22", "P.27", "P.30", "P.31", "P.32", "P.26", "P.28", "P.29", "P.4".
Demandas psicológicas	"P.33a", "P.33b", "P.33c", "P.33d", "P.33e", "P.33f", "P.34a", "P.34b", "P.34c", "P.34d", "P.35", "P.36".
Variedad/Contenido	"P.37", "P.38", "P.39", "P.40a", "P.40b", "P.40c", "P.40d".
Participación/Supervisión	"P.11a", "P.11b", "P.11c", "P.11d", "P.11e", "P.11f", "P.11g", "P.12a", "P.12b", "P.12c", "P.12d".
Interés por el trabajador/Compensación	"P.13a", "P.13b", "P.13c", "P.13d", "P.41", "P.42", "P.43", "P.44".
Desempeño de rol	"P.14a", "P.14b", "P.14c", "P.14d", "P.14e", "P.14f", "P.15a", "P.15b", "P.15c", "P.15d", "P.15e".
Relaciones y apoyo social	"P.16a", "P.16b", "P.16c", "P.16d", "P.17", "P.18a", "P.18b", "P.18c", "P.18d", "P.19", "P.20".
Estrés por dimensiones	"strestt", "stresps", "stresvc", "stresitc", "stresdr", "stresras", "stresau", "stresdp", "stresct", "strestot".
Nivel de estrés	"No", "Si"
SRQ	"No", "Si"
Complementarias	"rdinero", "averbal", "afisica", "angus", "epeso", "eSPO2", "epres".

Análisis de resultados

Como se observa en la Tabla 4-8 se estructuró el conjunto de datos con base a las preguntas sociodemográficas y las preguntas de nueve dimensiones de riesgo psicosocial laboral. Se incluyen variables relacionadas con los resultados denominadas "estrés por dimensiones", "nivel de estrés", resultados del *SRQ* y complementarias, donde constan, entre otras, estado del peso, nivel de oxígeno y estado de la presión sanguínea.

Resultados de dimensiones por nivel de estrés

Tabla 4-9: VALORES RESULTANTES DE LAS VARIABLES DIVIDIDAS EN “NO ESTRÉS” Y “ESTRÉS” POR DIMENSIÓN

Cod. estrés	Dimensiones									
	restt	resps	resau	resvc	resct	resras	resdr	resitc	resdp	strestot
0	180	113	253	287	206	199	224	322	206	312
1	161	228	88	54	135	142	117	19	135	29

Figura 4-3: Dimensiones divididas en estrés y no estrés




Figura 4-3: Dimensiones divididas en estrés y no estrés

Análisis de resultados

En las columnas de la Tabla 4-9 se observan los valores resultantes de cada una de las dimensiones de riesgos psicosociales, mientras que en cada fila constan los valores relacionados con “no estrés” y “estrés”, codificado con 0 y 1, respectivamente. Esta

subdivisión está elaborada acorde con los resultados del mapa de riesgos psicosociales y el estrés laboral.

En la Figura 4-3 se observa la distribución de los resultados clasificados en “no estrés” en color azul y “estrés” en color naranja. Se distingue de forma clara el desbalance que existe en los datos de las dimensiones Participación/Supervisión (stresps), Variedad/Contenido (stresvc), Interés por trabajador/Compensación (stresitc), Autonomía (stresau), y estrés total (strestot).

Resultados de la transformación en datos numéricos




Figura 4-4: Histogramas por dimensiones de riesgo psicosocial

Análisis de resultados

En la Figura 4-4 se evidencia el resultado del proceso de transformación de las variables categóricas, binarias y ordinales en variables numéricas. Cada histograma representa una dimensión de riesgo psicosocial y de las variables sociodemográficas, como ejemplo, se representa la variable “edad”. Algo similar ocurre con el resto de las variables del conjunto de datos.

Resultados del preprocesamiento de datos

Tabla 4-10: ESCALAMIENTO DE VARIABLES PARA KNN

	count	mean	std	min	25%	50%	75%	max
edad	341.0	0.391	0.249	0.0	0.25	0.500	0.500	1.0
nedu	341.0	0.254	0.218	0.0	0.00	0.333	0.333	1.0
exp	341.0	0.441	0.261	0.0	0.25	0.500	0.750	1.0
depre	341.0	0.018	0.132	0.0	0.00	0.000	0.000	1.0
angus	341.0	0.018	0.132	0.0	0.00	0.000	0.000	1.0
epeso	341.0	0.158	0.366	0.0	0.00	0.000	0.000	1.0
eSPO2	341.0	0.117	0.322	0.0	0.00	0.000	0.000	1.0
strestt	341.0	0.472	0.500	0.0	0.00	0.000	1.000	1.0
stresps	341.0	0.669	0.471	0.0	0.00	1.000	1.000	1.0
stresvc	341.0	0.158	0.366	0.0	0.00	0.000	0.000	1.0
stresitc	341.0	0.056	0.230	0.0	0.00	0.000	0.000	1.0
stresdr	341.0	0.343	0.475	0.0	0.00	0.000	1.000	1.0
stresras	341.0	0.416	0.494	0.0	0.00	0.000	1.000	1.0
stresau	341.0	0.258	0.438	0.0	0.00	0.000	1.000	1.0
stresdp	341.0	0.396	0.490	0.0	0.00	0.000	1.000	1.0
stresct	341.0	0.396	0.490	0.0	0.00	0.000	1.000	1.0
strestot	341.0	0.085	0.279	0.0	0.00	0.000	0.000	1.0
epres_2	341.0	0.015	0.120	0.0	0.00	0.000	0.000	1.0
epres_3	341.0	0.106	0.308	0.0	0.00	0.000	0.000	1.0
afisica_1	341.0	0.065	0.246	0.0	0.00	0.000	0.000	1.0
afisica_2	341.0	0.035	0.185	0.0	0.00	0.000	0.000	1.0
afisica_3	341.0	0.009	0.094	0.0	0.00	0.000	0.000	1.0
afisica_4	341.0	0.018	0.132	0.0	0.00	0.000	0.000	1.0
rdinero_1	341.0	0.067	0.251	0.0	0.00	0.000	0.000	1.0
rdinero_2	341.0	0.047	0.212	0.0	0.00	0.000	0.000	1.0
rdinero_3	341.0	0.009	0.094	0.0	0.00	0.000	0.000	1.0
rdinero_4	341.0	0.023	0.152	0.0	0.00	0.000	0.000	1.0
ecivil_2	341.0	0.724	0.448	0.0	0.00	1.000	1.000	1.0
ecivil_3	341.0	0.059	0.235	0.0	0.00	0.000	0.000	1.0
ecivil_4	341.0	0.050	0.218	0.0	0.00	0.000	0.000	1.0

Análisis de resultados

En la Tabla 4-10 se observa un fragmento de los resultados de la media, desviación estándar, cuartiles; y, valores mínimos y máximos de cada variable. Previamente las variables ordinales y numéricas fueron transformadas a una misma escala. La transformación es requerida para el cálculo de la distancia euclidiana del algoritmo *KNN*.

4.3. Resultados de la fase de modelamiento del algoritmo *K-Nearest Neighbour* (KNN)

División en entrenamiento y prueba

Tabla 4-11: DIVISIÓN DEL CONJUNTO DE DATOS EN ENTRENAMIENTO Y PRUEBA PARA KNN

Nombre	Entrenamiento y Prueba		
	Total datos	Datos de entrenamiento (80%)	Datos de prueba (20%)
Conjunto de datos	341	272	69

Análisis de Resultados

La Tabla 4-11 muestra la división del conjunto de datos en entrenamiento (80%) y prueba (20%), la función de ayuda utilizada fue “train_test_split” de “sk-learn”, que permite la división aleatoria de los datos. Previamente se identificaron las variables “X” e “y”.

Clasificación

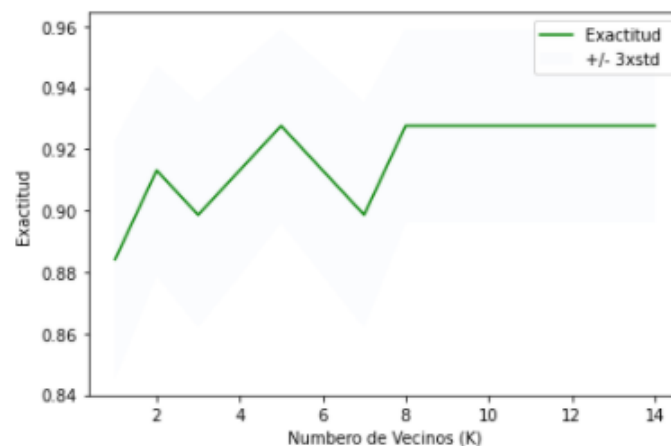


Figura 4-5: Valor de k en K -vecinos más cercanos

Análisis de resultados

Para evitar el sobre ajuste o sub-ajuste del modelo, se calculó la variable o valor k a través de la librería *KNeighborsClassifier* de *SciKit Learn* para problemas de clasificación. En la Figura 4-5 se observa la evaluación de exactitud para los valores de k entre 1 a 15 establecido para determinar el valor óptimo de k -vecinos, obteniéndose como mejor resultado $k = 5$.

Predicción

Tabla 4-12: PREDICCIÓN DE LA VARIABLE OBJETIVO CON KNN

```
# Modelamiento del algoritmo knn
# Se ingresan valores para cada una de las variables predictoras
# new Stres
newStres = pd.DataFrame([{'edad': 4, 'nedu': 3, 'exp': 2, 'epeso': 1, 'eSPO2': 2, 'strestt': 0,
                          'stresps': 1, 'stresau': 1, 'stresvc': 0, 'stresct': 1, 'stresras': 1,
                          'stresdr': 0, 'stresitc': 1, 'stresdp': 0}])

[0]
Distancias [[19.62001821 19.71121012 19.7220436 19.74301581 19.75201919]]
Indices [[307 318 314 328 294]]

      zedad      znedu      zexp      zepeso      zeSPO2      zstrestt      zstresps \
307  0.459935  1.834500  0.214089  2.373636  2.840188 -0.942809  0.703211
318  1.460754  0.340536  1.184627  2.373636  2.840188 -0.942809  0.703211
314  0.459935  1.834500  0.214089  2.373636  2.840188  1.060660  0.703211
328  1.460754  0.340536  1.184627  2.373636  2.840188 -0.942809 -1.422049
294  1.460754  1.834500  1.184627 -0.421295 -0.352089 -0.942809  0.703211

      zstresau zstresvc zstresct zstresras zstresdr zstresitc zstresdp
307 -0.57735 -0.433328  1.261141 -0.888523 -0.726698 -0.205294 -0.862316
318 -0.57735  2.307722  1.261141 -0.888523 -0.726698 -0.205294 -0.862316
314 -0.57735 -0.433328  1.261141 -0.888523 -0.726698 -0.205294 -0.862316
328 -0.57735 -0.433328 -0.792933  1.125463 -0.726698 -0.205294  1.159667
294 -0.57735 -0.433328 -0.792933 -0.888523 -0.726698 -0.205294 -0.862316

      strestot      Number
307          0  0.902941
318          0  0.935294
314          0  0.923529
328          0  0.964706
294          0  0.864706
```

Análisis de resultados

En la tabla 4-12 se observan las variables predictoras y los valores considerados para la predicción de la variable objetivo. De igual forma se identifican los resultados de la ejecución del algoritmo *KNN* en la clasificación del conjunto de datos. La salida del modelamiento, con cinco etiquetas en el conjunto de prueba muestra, la predicción en la columna “strestot” con el código cero que evidencia la ausencia de estrés (no hay estrés = 0).

De manera general, el ejemplo describe un conductor con una edad comprendida entre 51 y 65 años, con tercer nivel de educación, con una experiencia entre 5 y 9 años, sin sobrepeso, con un nivel de saturación de oxígeno adecuado, con valores de no estrés en las dimensiones VC, DR, DP y TT, mientras que en las dimensiones restantes constan valores de estrés, en este caso, el modelo predice no estrés.

Adicionalmente, se presupone que el estrés identificado en las dimensiones PS, AU, CT, RAS e ITC del modelamiento, se debe a la incidencia de los riesgos psicosociales que forman parte de las referidas dimensiones.

Evaluación del modelo

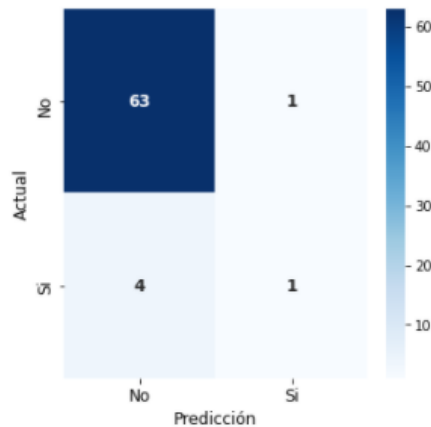


Figura 4-6: Matriz de Confusión KNN

Tabla 4-13: MÉTRICAS DE EVALUACIÓN DEL ALGORITMO KNN

	precision	recall	f1-score	support
0	0.94	0.98	0.96	64
1	0.50	0.20	0.29	5
accuracy			0.93	69
macro avg	0.72	0.59	0.62	69
weighted avg	0.91	0.93	0.91	69

K-NN Accuracy Score: 0.93
F1 Score: 0.29

Análisis de resultados

En la matriz de confusión de la Figura 4-6 se observa en forma de mapa de calor lo siguiente: 1 verdaderos positivos y 63 verdaderos negativos (valores correctamente predichos); y, 4 falsos negativos y 1 falso positivo, que corresponden a los errores de tipo I y II, respectivamente (el modelo se ha equivocado).

En la Tabla 4-13 la puntuación *f1* (0.96) indica que el modelo maneja perfectamente la clase 0; mientras que, la puntuación *f1* (0.29) señala que el algoritmo no logra clasificar la clase 1 correctamente.

La columna *support* (soporte) indica la cantidad de muestras en cada clase, en este caso las clases están desequilibradas y consecuentemente existe mayor precisión en 0 que en 1.

El índice *macro avg* (*avg = average*) o promedio macro es el valor en promedio de las dos clases.

Accuracy Score o puntuación de exactitud del modelo es 0.93 o 93%, que se refiere a las predicciones correctas frente al total.

4.4. Resultados de la fase de modelamiento del algoritmo **Árbol de Decisión (DT)**

División en entrenamiento y prueba

Tabla 4-14: DIVISIÓN DEL CONJUNTO DE DATOS EN ENTRENAMIENTO Y PRUEBA PARA *DT*

Nombre	Entrenamiento y Prueba		
	Total datos	Datos de entrenamiento (80%)	Datos de prueba (20%)
Conjunto de datos	341	272	69

Análisis de resultados

La Tabla 4-14 muestra la división del conjunto de datos en entrenamiento (80%) y prueba (20%), la función de ayuda utilizada fue “train_test_split” de “sk-learn”, que permite la división aleatoria de los datos. Previamente se identificaron las variables “X” e “y”. Además, se efectuó con antelación la normalización y estandarización de datos.

Composición del conjunto de datos

Tabla 4-15: COMPOSICIÓN PORCENTUAL DEL CONJUNTO DE DATOS

```
y_trainset.value_counts(normalize=True).sort_index()
```

```
0    0.922794  
1    0.077206  
Name: strestot, dtype: float64
```

```
y_testset.value_counts(normalize=True).sort_index()
```

```
0    0.884058  
1    0.115942  
Name: strestot, dtype: float64
```

Análisis de resultados

En la Tabla 4-15 se observa la composición porcentual de cada clase en el conjunto de datos dividido en entrenamiento y prueba para las dos clases (no estrés y estrés). El conjunto de datos es principalmente “no estrés”, tanto en entrenamiento como en prueba.

Evaluación del modelo

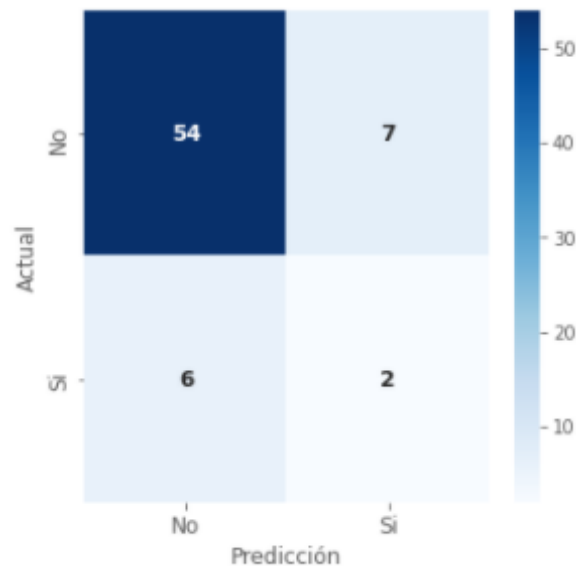


Figura 4-7: Matriz de Confusión *DT*

Tabla 4-16: MÉTRICAS DE EVALUACIÓN DEL ALGORITMO *DT*

	precision	recall	f1-score	support
0	0.90	0.89	0.89	61
1	0.22	0.25	0.24	8
accuracy			0.81	69
macro avg	0.56	0.57	0.56	69
weighted avg	0.82	0.81	0.82	69
DT Accuracy Score: 0.81				
F1 Score: 0.24				

Análisis de resultados

En la matriz de confusión de la Figura 4-7 se observa en forma de mapa de calor lo siguiente: 2 verdaderos positivos y 54 verdaderos negativos (valores correctamente predichos); y, 6 falsos negativos y 7 falsos positivos, que corresponden a los errores de tipo I y II, respectivamente (el modelo se ha equivocado).

La puntuación *f1* (0.89) indica que el modelo maneja muy bien la clase 0; mientras que, la puntuación *f1* (0.24) indica que el modelo no logra clasificar la clase 1 correctamente. *Accuracy Score* o puntuación de exactitud del modelo es 0.81 o 81%, que se refiere a las predicciones correctas frente al total (Tabla 4-16).

Predicción

Tabla 4-17: PREDICCIÓN DEL ÁRBOL DE DECISIÓN

```
predTree = stresTree.predict(X_testset)
print (predTree [0:8])
print (y_testset [0:8])

[0 0 0 0 0 0 0 0]
102    1
125    0
11     0
248    1
238    0
337    0
112    0
147    0
Name: stresTot, dtype: int64
```

Análisis de resultados

En la ejecución del algoritmo *DT* para realizar la clasificación en base al conjunto de datos, se estableció como salida del modelamiento en el conjunto de prueba ocho etiquetas. Los resultados de la predicción se visualizan en la tabla 4-17 en forma de columna con el código cero y uno, no estrés y estrés, respectivamente. El resultado evidencia estrés en las etiquetas 102 y 248; mientras que, ausencia de estrés (no hay estrés = 0) en el resto de las etiquetas.

Visualización del árbol




Figura 4-8: Árbol de Decisión

Análisis de resultados

La Figura 4-8 representa un extracto (tres niveles y siete nodos) de la figura completa del modelado del algoritmo Árbol de Decisión, debido a que por su amplitud requiere

de un mayor espacio para ser visualizado. El gráfico completo se puede observar en el Anexo 3.

En general, la información que brinda la Figura 4-8 completa es la que sigue: (i) el árbol de decisión tiene 10 niveles y 63 nodos; (ii) la “condición” si es un nodo donde se toma alguna decisión; (iii) el valor “Gini” que indica si los elementos seleccionados son de la misma clase, si es cero el nodo es totalmente puro; (iv) “samples” es el número de muestras que satisfacen las condiciones para llegar a un nodo; y, (v) “value” que se refiere a cuántas muestras de cada clase llegan al nodo.

Por ejemplo: Si la variable objetivo es, tiene o no estrés, y las variables explicativas son las dimensiones de riesgo psicosocial laboral (X1 a X9), la interpretación del primer nodo del árbol de decisión sería: si el valor de X9 (variable autonomía) es menor o igual 0.5, entonces hay estrés. Si por el contrario, el valor es mayor que 0.5, no hay estrés. El valor Gini de 0.142 indica que las clases no son homogéneas. El número de individuos de la muestra que satisfacen las condiciones para llegar a este nodo son 272, de los cuales 251 no tienen estrés mientras que 21 si lo tienen.

Los resultados obtenidos también revelan que el conjunto de datos se encuentra sin balancear o en desequilibrio. Al examinar $samples = 272$, se aprecia que los valores de estrés = 21 y sin estrés = 251, evidencian el desbalance. Con el valor del índice Gini = 0.142, se corrobora esta afirmación.

Por otro lado, la figura del Árbol de Decisión permite constatar la aplicación de la Fase 1 del AA, “comprender los datos”, que se refiere a la visualización de datos multidimensionales (Shah, 2016), en este caso se observa la representación gráfica de los datos de las variables predictivas y variable objetivo usados en la predicción con el algoritmo *DT*.

4.5. Resultados de la fase de modelamiento del algoritmo Máquina de Vectores de Soporte (SVM) con datos sin equilibrar

Correlación entre dimensiones del Fpsico

Tabla 4-18: CORRELACIÓN DE DATOS

	edad	nedu	exp	eSPO2	epres	epeso	strestt	stresps	stresau	stresvc	stresct
edad	1.000000	-0.358065	0.612857	0.028250	0.016115	0.005789	-0.010863	-0.084839	-0.008274	-0.064824	0.033553
nedu	-0.358065	1.000000	-0.318065	0.008033	0.023393	0.037990	-0.031001	0.126871	-0.004279	-0.026552	0.073662
exp	0.612857	-0.318065	1.000000	0.012509	0.011790	-0.020779	0.032779	-0.122285	0.011817	-0.075908	0.055590
eSPO2	0.028250	0.008033	0.012509	1.000000	0.988177	0.840409	-0.052678	0.004940	-0.090029	0.041581	0.058967
epres	0.016115	0.023393	0.011790	0.988177	1.000000	0.829446	-0.046728	-0.007240	-0.076557	0.040090	0.051698
epeso	0.005789	0.037990	-0.020779	0.840409	0.829446	1.000000	-0.040155	-0.001802	-0.053888	0.009872	0.010212
strestt	-0.010863	-0.031001	0.032779	-0.052678	-0.046728	-0.040155	1.000000	-0.058006	-0.208732	0.024206	-0.044912
stresps	-0.084839	0.126871	-0.122285	0.004940	-0.007240	-0.001802	-0.058006	1.000000	0.030772	0.100589	0.085813
stresau	-0.008274	-0.004279	0.011817	-0.090029	-0.076557	-0.053888	-0.208732	0.030772	1.000000	0.019542	0.043323
stresvc	-0.064824	-0.026552	-0.075908	0.041581	0.040090	0.009872	0.024206	0.100589	0.019542	1.000000	-0.006214
stresct	0.033553	0.073662	0.055590	0.058967	0.051698	0.010212	-0.044912	0.085813	0.043323	-0.006214	1.000000
stresras	-0.057967	-0.030386	-0.107029	-0.215503	-0.205148	-0.187174	0.023308	-0.113037	0.032014	0.024657	-0.221595
stresdr	0.094362	-0.050994	-0.052405	-0.071495	-0.059710	-0.110451	-0.040096	-0.029248	-0.002732	0.041829	-0.180871
stresitc	0.072011	0.019577	-0.012486	-0.048820	-0.049871	-0.035328	-0.024858	0.062366	0.061263	0.139771	-0.092074
stresdp	0.067964	-0.034662	0.082562	-0.127388	-0.135215	-0.071915	0.003135	-0.016102	-0.066310	0.108764	0.031320
strestot	-0.074756	0.011702	-0.078755	-0.045797	-0.047070	-0.045855	-0.014574	0.169963	0.276683	0.299704	0.140140




Figura 4-9: Mapa de Calor de la correlación de Spearman

Análisis de resultados

En la tabla 4-18 se observa que el coeficiente de correlación es positivo en algunas de las variables objeto de análisis, especialmente las relacionadas con los riesgos

psicosociales, y están en el rango de 0.14 a 0.30. Estos valores indican de forma general, que las variables tienden a aumentar a la vez y la relación que tienen es lineal moderada.

En el mapa de calor de la Figura 4-9 se identifica el grado de asociación lineal (Correlación de Spearman) entre las diferentes variables. Con el análisis se busca determinar las variables que pueden ser utilizadas como predictoras en el presente estudio.

En cuanto a las variables SPO2, pres y peso, se observa correlaciones positivas y negativas con las dimensiones del Fpsico; sin embargo, no son significativas. Algo similar se aprecia en las correlaciones de las variables sociodemográficas con las dimensiones de los riesgos psicosociales, observándose que tampoco son estadísticamente significativas.

El mapa de calor también señala una correlación de 0.13 entre la variable nivel de educación (nedu) y la variable participación/supervisión (stresps), hallándose mediante la prueba U de Mann – Whitney, la existencia de cinco de once ítems (cambios en equipos y materiales, cambios en manera de trabajar, cambios en reorganizar áreas de trabajo, participación en contratación de empleados y elaboración de normas de trabajo) que presentan diferencias significativas según la variable de agrupamiento, lo que permite presuponer que el nivel de participación en los dos grupos es diferente (nivel de significancia igual a 0.047 en el ítem cambios en reorganizar áreas de trabajo, mientras que en el resto de ítems objeto de análisis el nivel de significancia es igual a 0.000).

División en entrenamiento y prueba

Tabla 4-19: DIVISIÓN DEL CONJUNTO DE DATOS EN ENTRENAMIENTO Y PRUEBA PARA SVM

Nombre	Entrenamiento y Prueba		
	Total datos	Datos de entrenamiento (80%)	Datos de prueba (20%)
Conjunto de datos	341	272	69

Análisis de resultados

La Tabla 4-19 muestra la división del conjunto de datos en entrenamiento (80%) y prueba (20%), la función de ayuda fue “train_test_split” de “sk-learn”, que permite la división aleatoria de los datos, previamente se identificaron las variables “X” e “y”.

Predicción

Tabla 4-20: NIVEL DE ESTRÉS PREDICHO CON SVM – DATOS SIN EQUILIBRAR

```
feature_df = df[['restt', 'resps', 'resvc', 'resitc', 'resdr', 'resras', 'resau', 'resdp', 'resct']]
X = np.asarray(feature_df)
X[0:15]

array([[ 4, 23, 23, 24, 17, 21, 24, 27, 33],
       [11, 34, 23, 22, 18, 19, 29, 38, 35],
       [ 4, 35, 24, 15, 17, 21, 31, 29, 35],
       [ 4, 35, 23, 21, 18, 20, 27, 31, 39],
       [13, 20, 24, 19, 17, 21, 30, 35, 36],
       [ 4, 20, 11, 18, 18, 19, 27, 31, 32],
       [ 4, 11, 25, 22, 17, 21, 26, 20, 31],
       [ 4, 11, 22, 20, 18, 20, 43, 13, 30],
       [11, 11,  7, 16, 17, 21, 27, 24, 36],
       [ 4, 11, 24, 22, 16, 19, 21, 39, 33],
       [ 4, 11, 22, 21, 17, 29, 35, 24, 31],
       [ 4, 11, 22, 21, 16, 32, 27, 31, 33],
       [ 8, 20, 22, 21, 14, 33, 21, 22, 25],
       [13, 20, 23, 22, 16, 30, 33, 29, 35],
       [11, 24, 22, 21, 25, 37, 28, 38, 36]], dtype=int64)

df['strestot'] = df['strestot'].astype('int')
y = np.asarray(df['strestot'])
y [0:15]

array([0, 0, 0, 0, 0, 0, 1, 0, 1, 0, 0, 0, 0, 0, 0])

yhat = clf.predict(X_test)
yhat [0:15]

array([0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0])
```

Análisis de resultados

Durante la ejecución del algoritmo para la clasificación del nuevo estrés se introdujeron datos en las nueve dimensiones y se modelaron las etiquetas en el conjunto de prueba, los resultados de la predicción para la categoría “no estrés” se muestra en la Tabla 4-20 (no hay estrés = 0).

Evaluación del modelo




Figura 4-10: Matriz de Confusión de SVM datos sin equilibrar

Tabla 4-21: MÉTRICAS DE EVALUACIÓN DEL ALGORITMO SVM – DATOS SIN EQUILIBRAR

	precision	recall	f1-score	support
0	0.93	1.00	0.96	64
1	0.00	0.00	0.00	5
accuracy			0.93	69
macro avg	0.46	0.50	0.48	69
weighted avg	0.86	0.93	0.89	69

SVM Accuracy Score: 0.93

Análisis de resultados

En la matriz de confusión de la Figura 4-10 se observa en forma de mapa de calor que hay 62 verdaderos negativos y cero verdaderos positivos (valores correctamente predichos); de igual manera, existen cinco falsos negativos y dos falsos positivos, que corresponden a los errores de tipo I y II, respectivamente (el modelo se ha equivocado).

La puntuación *f1* (0.96) indica que el modelo maneja perfectamente la clase 0; mientras que, la puntuación *f1* (0.00) indica que el modelo no logra clasificar la clase 1 correctamente. *Accuracy Score* o puntuación de exactitud del modelo es 0.93 o 93%, que se refiere a las predicciones correctas frente al total (Tabla 4-21).

Evaluación del modelo - AUC

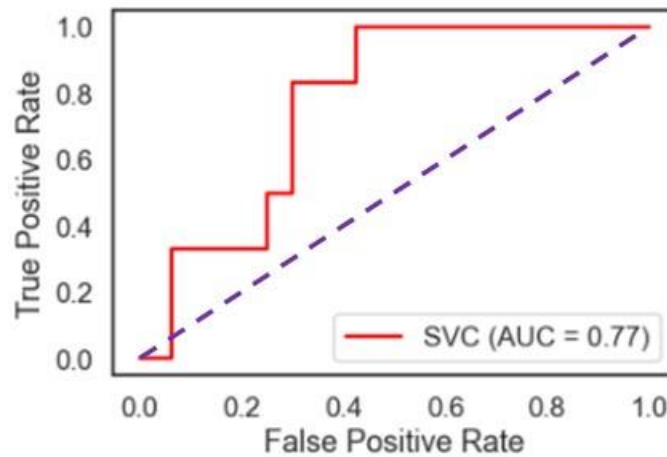


Figura 4-11: Área bajo la curva (AUC) de SVM sin datos equilibrados

Análisis de resultados

La curva ROC es un gráfico de la tasa de verdaderos positivos versus la tasa de falsos positivos en varios umbrales de probabilidad, que van de 0 a 1. En donde, la tasa de verdaderos positivos equivale a *recall*, y la tasa de falsos positivos es la fracción de negativos que se identifican incorrectamente como positivos.

En la Figura 4-11, la línea punteada es la línea de base que representa la conjetura aleatoria, donde la tasa de verdaderos positivos aumenta linealmente con la tasa de falsos positivos; su AUC es 0,5. La línea continua es la gráfica ROC (Receiver Operating Characteristic) del modelo, y el área bajo la curva ROC, también conocida como AUC (por sus siglas en inglés), es de 0.77, lo cual significa que hay el 77% de probabilidad que el modelo SVM pueda clasificar correctamente entre “sin estrés” y “con estrés”.

Según Liu (2020), la siguiente regla empírica permite determinar si un modelo es bueno: los modelos de clasificación que logran un AUC de 0,7 a 0,8 se consideran aceptables; de 0.8 a 0.9 son muy buenos y cualquier valor superior a 0.9 es excelente (Liu, 2020). En este estudio, el valor obtenido del AUC es 0,77 y considerado aceptable.

4.6. Resultados de la fase de modelamiento del algoritmo Máquina de Soporte de Vectores (SVM) con datos equilibrados

Información original del conjunto de datos de riesgos psicosociales:

Counter ({0: 312, 1: 29})

Información del conjunto de datos de riesgos psicosociales equilibrado:

Sampling_strategy {0: 29, 1: 29}

y: Counter ({0: 29, 1: 29})




Figura 4-12: Datos sin equilibrar y equilibrados en SVM

Análisis de resultados

En la Figura 4-12 se visualiza, en la primera circunferencia la distribución del conjunto de datos original, datos desbalanceados, con un 91.5% de respuestas que evidencian sin estrés y el 8.5% con estrés.

En la segunda circunferencia, una vez realizado el procedimiento de balanceo o equilibrio de datos, que el 50% de las respuestas evidencian sin estrés y el otro 50% con estrés.

Predicción

Tabla 4-22: NIVEL DE ESTRÉS PREDICHO CON SVM – DATOS EQUILIBRADOS

```
y_pred = clf.predict(X_test)
print (y_pred [0:15]) # Imprime la predicción del modelo en la primera fila
print (y_test [0:15])

[0 0 0 0 0 0 1 1 0 1 0 0 0 0 1]
4      0
20     0
56     1
24     0
12     0
28     0
35     1
32     1
6      0
43     1
7      0
25     0
11     0
14     0
37     1
Name: strestot, dtype: int32
```

Análisis de resultados

Para obtener los resultados mostrados en la Tabla 4-22, durante la ejecución del algoritmo para la clasificación del estrés predicho, se introdujeron datos en las variables predictoras y se realizó el modelamiento en el conjunto de prueba, los resultados de la predicción es “no estrés” (no hay estrés = 0) y “estrés” (se evidencia estrés = 1).

Evaluación del modelo




Figura 4-13: Matriz de Confusión de SVM con datos equilibrados

Tabla 4-23: MÉTRICAS DE EVALUACIÓN DEL ALGORITMO SVM – DATOS EQUILIBRADOS

	precision	recall	f1-score	support
0	0.88	1.00	0.93	7
1	1.00	0.88	0.93	8
accuracy			0.93	15
macro avg	0.94	0.94	0.93	15
weighted avg	0.94	0.93	0.93	15

SVM Accuracy Score: 0.93

Análisis de resultados

En la matriz de confusión de la Figura 4-13, se observa en forma de mapa de calor que hay siete verdaderos negativos y siete verdaderos positivos (valores correctamente predichos); de igual manera, existe un falso negativo y ningún falso positivo, que corresponden a los errores de tipo I y II, respectivamente (el modelo se ha equivocado).

La puntuación *f1* (0.93) indica que el modelo maneja perfectamente la clase 0; lo mismo ocurre con la clasificación de la clase 1, la puntuación *f1* (0.93) indica que el modelo logra clasificar esta correctamente. *Accuracy Score* o puntuación de exactitud del modelo es 0.93 o 93%, que se refiere a las predicciones correctas frente al total.

Evaluación del modelo

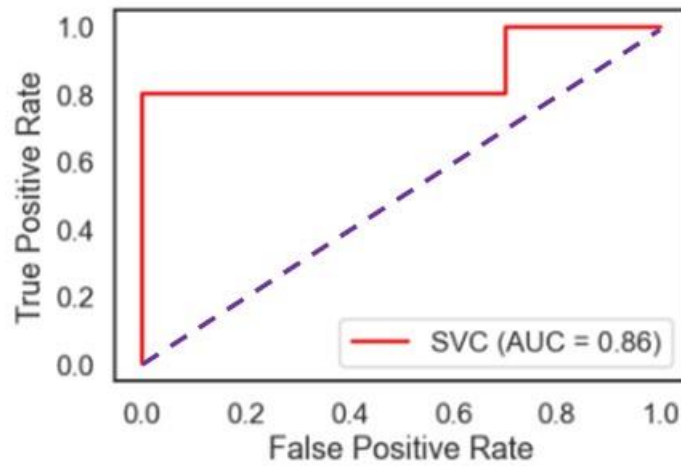


Figura 4-14: Área Bajo la Curva (*AUC*) de *SVM* con datos equilibrados

Análisis de resultados

En la Figura 4-14 se observa que el área bajo la curva ROC (Receiver Operating Characteristic), conocida como *AUC*, es de 0.86, lo que significa que hay el 86% de probabilidad que el modelo *SVM* pueda clasificar correctamente entre “sin estrés” y “con estrés”. Este valor indica que el modelo es muy bueno.

4.7. Resultados de la fase de evaluación general de los modelos *KNN*, *DT* y *SVM*

Evaluación de los algoritmos

Tabla 4-24: RESULTADOS DE INDICADORES DE EVALUACIÓN DE LOS ALGORITMOS

Algoritmo	<i>Jaccard</i>	<i>F1-score</i>
K-vecinos más cercanos	0.00	0.89
Árbol de decisión	0.20	0.89
Máquina de vectores de soporte – datos sin equilibrar	0.00	0.89
Máquina de vectores de soporte – datos equilibrados	0.87	0.93

Análisis de resultados

Los resultados de la Tabla 4-24 muestran, en las tres primeras filas, el valor del índice *Jaccard* y *F1-score* de los algoritmos *KNN*, *DT* y *SVM* con los datos originales sin balancear y al final de la tabla el algoritmo *SVM* con los datos balanceados o equilibrados.

Los valores del *F1-score* muestran que el algoritmo *SVM* con datos equilibrados tiene un rendimiento del 93% en la clasificación del estrés laboral en conductores de transporte urbano de pasajeros, siendo el rendimiento superior a los otros algoritmos cuando están con los datos sin equilibrar.

Algo similar ocurre con los valores registrados por el índice *Jaccard* que señala al modelo *SVM* con datos equilibrados como el que mejor establece el grado de similitud entre los conjuntos de datos en comparación con los modelos *DT*, *KNN* y *SVM* cuando se efectúa el modelamiento con los datos sin balancear.

Los resultados alcanzados con los algoritmos *DT*, *KNN* y *SVM* están en consonancia con los obtenidos por Elamrani Abou El Assad et al. (2020) y Hegde & Rokseth (2020) en los análisis del comportamiento de conductores y en la resolución de problemas basados en evaluación de riesgos por industrias.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

En el presente Trabajo de Titulación se estudiaron los riesgos psicosociales laborales, su principal consecuencia el estrés laboral y la predicción mediante técnicas de aprendizaje automático no supervisado, en el transporte urbano de pasajeros de la ciudad de Ambato, por medio de la metodología para la identificación, análisis y evaluación de riesgos psicosociales del INSHT de España y el modelo *Cross Industry Standard Process for Data Mining*. En el planteamiento de las principales conclusiones del estudio llevado a efecto, se tomaron como punto de referencia los objetivos planteados en el mismo.

Para lograr una apropiada visualización se clasificaron los datos en unidimensionales, bidimensionales y multidimensionales. En los dos primeros casos, se utilizaron medidas de tendencia central y gráficos como el histograma, diagrama de dispersión, diagrama de caja y mapa de calor para la correlación de Spearman; mientras que la visualización de datos multidimensionales se aplicó en la elaboración del gráfico Árbol de Decisión.

El conjunto de datos original presentó un desbalance significativo en los resultados de las dimensiones de riesgo psicosocial laboral y en los resultados de estrés y no estrés en las dimensiones “participación / supervisión”, “variedad / contenido” “interés por el trabajo / compensación”, “desempeño de rol”, “autonomía”, “demanda psicológica” y “carga de trabajo”, dicho desbalance se reflejó en la evaluación de cada uno de los algoritmos con el indicador *F1-score*, donde los valores obtenidos evidencian una buena clasificación de la etiqueta 0 (sin estrés) y una deficiente clasificación de la etiqueta 1 (estrés).

En el proceso de modelamiento se usaron tres algoritmos de clasificación denominados k-vecinos más cercanos, árbol de decisiones y máquina de soporte de vectores que se consideran los más apropiados para alcanzar el objetivo general de la investigación, debido a que se ajustan a las características, tamaño del conjunto de datos, interpretabilidad y son no paramétricos; además, son los que se han aplicado frecuentemente en los últimos 10 años, en análisis del comportamiento de conductores

y en la resolución de problemas basados en evaluación de riesgos por industrias, de acuerdo con lo señalado por Elamrani Abou El Assad et al. (2020) y Hegde & Rokseth (2020).

Dado que en el presente trabajo de investigación se procura realizar predicciones en base a un conjunto de datos fue necesario establecer, con cierta precisión, el número de registros mínimos necesarios para conseguir un adecuado grado de confiabilidad en el pronóstico. Para este efecto, se utilizó la regla para clasificar establecida por Delmaster y Hancock (2001), lo que permitió constatar que el conjunto de datos es apropiado para realizar inferencia estadística y aplicaciones con los modelos de aprendizaje automático *K-Nearest Neighbour*, *Support Vector Machine* y *Decision Tree*.

Metodológicamente se pudieron soportar con evidencia empírica que las variables predictoras seleccionadas aportaban a la predicción del estrés como variable objetivo; si bien las dimensiones de riesgos psicosociales laborales tienen este enfoque, el uso de la correlación de Spearman en el estudio corroboraron esta relación positiva. Asimismo, se pudo evidenciar que una vez pronosticado el estrés se podía determinar que dimensión o dimensiones tenían mayor incidencia y consecuentemente facilitó la identificación de los riesgos psicosociales involucrados.

La evaluación de los algoritmos supervisados no paramétricos *KNN*, *DT* y *SVM* para determinar el que presenta mejor rendimiento y valora de forma adecuada el grado de similitud entre los conjuntos de datos, se realizó con los índices *F1-score* y *Jaccard*, con datos sin equilibrio; además, se consideró el modelamiento del algoritmo *SVM* con datos equilibrados.

Para la obtención del conjunto de datos equilibrados y poder realizar predicciones con algoritmos de aprendizaje automático existen diversos métodos entre los que se incluyen *Upsampling* y *Downsampling* (Muestreo ascendente y descendente); en esta investigación se empleó *downsampling* (reducción de la clase mayoritaria al mismo número de datos constantes en la clase minoritaria); en nuestro caso, reducir la clase mayoritaria “sin estrés” a la clase minoritaria “estrés”. Con esta aplicación se obtuvo una mayor precisión y similitud en el conjunto de datos cuando se aplicó *SVM*.

Los valores de los índices *F1-score* y *Jaccard* muestran que el algoritmo *SVM* con datos equilibrados tiene el rendimiento más alto (93%) en la clasificación del estrés

laboral y es el que mejor establece el grado de similitud entre los conjuntos de datos (87%), en comparación con los modelos *DT*, *KNN* y *SVM* cuando estos algoritmos se modelan con datos sin equilibrar. En consecuencia, en el presente trabajo realizado el modelo *SVM* con datos equilibrados se destaca en la predicción del estrés en la población objeto de estudio y subsecuentemente en la identificación de los riesgos psicosociales laborales que los originan, a través de las nueve dimensiones que se emplean en el cuestionario Fpsico del INSHT de España.

5.2. Recomendaciones

Considerando el proceso de investigación llevado a cabo, así como el trabajo de campo y el correspondiente análisis de datos, a continuación se presentan las siguientes recomendaciones para investigaciones futuras.

Si bien, el uso de los algoritmos utilizados permiten realizar la clasificación de “estrés” y “sin estrés” con un aceptable grado de precisión, lo cual contribuye a la consecución de los objetivos planteados en esta investigación; es necesario mencionar la existencia de otros algoritmos supervisados no paramétricos como Naive Bayes que también pueden ser aplicados a clasificación y que no se emplea en esta investigación, debido a la limitación relacionada con la extensión del trabajo de titulación. Por otro lado, no se sugiere redes neuronales artificiales, debido a las características propias del conjunto de datos empleado.

Es común encontrar conjuntos de datos sin equilibrio y el conjunto de datos sobre riesgos psicosociales laborales usado en la presente investigación no escapa a esta realidad. Sin embargo, este inconveniente puede ser solventado con el uso de metodologías existentes para su tratamiento como *Upsampling* y *Downsampling*, entre otros, que presentan ventajas y desventajas, lo que implicaría en futuras investigaciones, que se realice su modelamiento con varias de estas metodologías para identificar la que presenta mejores resultados, acorde con las características del estudio.

Aun cuando en el modelamiento de los algoritmos utilizados se usa la técnica Hold-out cross validation (validación cruzada Hold-out) para evaluar y probar su rendimiento, existen otras técnicas que podrían ser aplicadas en futuras investigaciones como: *K-folds*, *Leave-one-out*, *Leave-p-out*, *Stratified K-folds*, *Nested K-folds* y *Complete*.

BIBLIOGRAFÍA

- Al-shargie, F., Tang, T. B., Badruddin, N., & Kiguchi, M. (2018). Towards multilevel mental stress assessment using SVM with ECOC: an EEG approach. *Medical & Biological Engineering & Computing*, 56(1), 125–136. <https://doi.org/10.1007/s11517-017-1733-8>
- Arias, F., & Heredia, V. (2000). *Administración de recursos humanos para el alto desempeño*. México D.F.: Trillas.
- Bravo, C., & Nazar, G. (2015). Riesgo psicosocial en el trabajo y salud en conductores de locomoción colectiva urbana en Chile. *Jul.-Dic*, 23(2), 105–114. Retrieved from <http://www.scielo.org.ve/pdf/st/v23n2/art04.pdf>
- Brocal, F. (2014). *Metodología para la identificación de riesgos laborales nuevos y emergente en los procesos avanzados d fabricación industrial*. UNED. Retrieved from <http://e-spacio.uned.es/fez/eserv/bibliuned:masterComEdred-Arodriguez/Documento.pdf>
- Bustos, H. S., Pareto, N. M., & Marchetti, P. B. (2016). Riesgos Psicosociales en Conductores de Transporte de Carga Autopercepción de Salud y Siniestralidad Laboral. *Ciencia & Trabajo*, (50), 67–74.
- Chaparro, E., & Guerrero, J. (2001). Working and health conditions of drivers of a public transportation Company in Bogotá, D. C. *Revista de Salud Pública*, 3, 171–187.
- Chiavenato, I. (2000). *Administración de recursos humanos* (5th ed.). Santa Fé de Bogotá: McGraw-Hill.
- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *Springer*. Retrieved from <https://link.springer.com/article/10.1186/s12864-019-6413-7>
- Consejo Andino de Ministros de Relaciones Exteriores. (2018). Instrumento Andino de Seguridad en el Trabajo, 12. Retrieved from <http://www.industrias.ec/archivos/CIG/file/SEGURIDAD/DecisionCAN584.pdf?fbclid=IwAR0XFonlXrrO8BIo9LvoyMt5O8rGbqqb968ZaUtQATmDe>

oUkKDv7Y4I1Wbo

- Elamrani Abou El Assad, Z., Mousannif, H., Al Moatassime, H., & Karkouch, A. (2020). The application of machine learning techniques for driving behavior analysis: A conceptual framework and a systematic literature review. *Engineering Applications of Artificial Intelligence*, 87, 103312. <https://doi.org/10.1016/j.engappai.2019.103312>
- Elovainio, M., Kivimäki, M., & Vahtera, J. (2002). Organizational justice: Evidence of a new psychosocial predictor of health. *American Journal of Public Health*, 92(1), 105–108. <https://doi.org/10.2105/AJPH.92.1.105>
- Elsler, D., Takala, J., & Remes, J. (2017). Comparación a nivel internacional del coste de los accidentes y las enfermedades relacionadas con el trabajo. *Agencia Europea Para La Seguridad y La Salud En El Trabajo (EU-OSHA)*, 1–10. Retrieved from <https://osha.europa.eu/es/tools-and-publications/publications/international-comparison-cost-work-related-accidents-and/view>
- Escolano, F., Cazorla, M., Alfonso, M., & Lozano, M. (2003). *Inteligencia Artificial* (First). Madrid: Thomson Ediciones. Retrieved from https://books.google.com.ec/books?id=_spC6S7UfZgC&printsec=frontcover&hl=es&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false
- EU-OSHA. (2010). European Survey of Enterprises on New and Emerging Risks. Retrieved from https://europa.eu/european-union/about-eu/agencies/eu-osha_es
- Eurofound and EU-OSHA. (2014). *Psychosocial Risks in Europe - Prevalence and Strategies for Prevention*. <https://doi.org/10.2806/70971>
- Evans, G. W., & Carrere, S. (1991). Traffic congestion, perceived control, and psychophysiological stress among urban bus drivers. *Journal of Applied Psychology*, 76(5), 658–653.
- Ferrer, R., Guilera, G., & Peró, M. (2011). *Propiedades psicométricas del instrumento de valoración de riesgos psicosociales del Instituto Nacional de Seguridad e Higiene en el Trabajo (Fpsico)*. Barcelona. Retrieved from <https://www.insst.es/documents/94886/96076/Informe+justificación.pdf/513898>

23-888d-4d5b-ae6c-7deee1b3d3de

- Frutos, M. (2014). *Relación entre los modelos de gestión de recursos humanos y los niveles de estrés laboral y burnout en los profesionales de enfermería de atención especializada*. Universidad de León.
- Hasseim, A. A., Sudirman, R., & Khalid, P. I. (2013). Handwriting Classification Based on Support Vector Machine with Cross Validation. *Scientific Research*. <https://doi.org/10.4236/eng.2013.55B017>
- Hegde, J., & Rokseth, B. (2020). Applications of machine learning methods for engineering risk assessment – A review. *Safety Science*, *122*, 104492. <https://doi.org/10.1016/j.ssci.2019.09.015>
- Instituto Nacional de Seguridad e Higiene en el Trabajo, E. (2015). Algunas orientaciones para evaluar los factores de riesgo psicosocial. *Datos Abiertos*, 106.
- internetsociety. (2017). Artificial Intelligence and Machine Learning: Policy Paper. Retrieved November 10, 2020, from https://www.internetsociety.org/wp-content/uploads/2017/08/ISOC-AI-Policy-Paper_2017-04-27_0.pdf
- Ivancevich, J. M., & Matteson, M. T. (1980). Optimizing human resources: A case for preventive health and stress management. *Organizational Dynamics*, *9*(2), 5–25. [https://doi.org/10.1016/0090-2616\(80\)90037-6](https://doi.org/10.1016/0090-2616(80)90037-6)
- Ivancevich, J. M., Matteson, M. T., Freedman, S. M., & Phillips, J. S. (1990). Worksite stress management interventions. *American Psychologist*, *45*(2), 252–261. <https://doi.org/10.1037/0003-066X.45.2.252>
- Jabbar, M. A., Deekshatulu, B. L., & Chandra, P. (2013). Classification of Heart Disease Using K- Nearest Neighbor and Genetic Algorithm. *Procedia Technology*, *10*, 85–94. <https://doi.org/10.1016/j.protcy.2013.12.340>
- Julian, D. (2016). *Designing Machine Learning Systems with Python* (First). Birmingham B3 2PB, UK.: Packt Publishing Ltd. Retrieved from <https://www.packtpub.com/>
- Leka, S., & Jain, A. (2010). *Health Impact of Psychosocial Hazards at Work: An Overview*. Geneva: World Health Organization.

- Liu, Y. (2020). *Python Machine Learning By Example (Third)*. Birmingham B3 2PB, UK.: Packt Publishing Ltd. Retrieved from www.packt.com
- Luceño, L., Martín, J., Jaén, M., & Díaz, E. (2005). Evaluación de Factores Psicosociales en el Entorno Laboral. *EduPsykhé*, 4(1), 19–42.
- Marsland, S. (2015). *MACHINE LEARNING An Algorithmic Perspective (Second)*. Boca Raton, FL: Taylor & Francis Group. Retrieved from <https://taylorandfrancis.com>
- Meliá, J., Nogareda, C., Matilde, L., Duro, A., Peiró, J., Salanova, M., & Gracia, D. (2006). Principios comunes para la evaluación de los riesgos psicosociales en la empresa. *Perspectivas de Intervención En Riesgos Psicosociales. Evaluacion de Riesgos*, 13–36. Retrieved from <http://www.uv.es/meliajl/Papers/2006FTNCap1.pdf>
- Minsky, M. (1986). *La sociedad de la mente: La inteligencia humana a la luz de la inteligencia artificial (First)*. Buenos Aires: Galapago Ediciones.
- Mintzberg, H., & Quinn, J. (1993). *EL PROCESO ESTRATÉGICO*. (P. Hall, Ed.) (2nd ed.).
- Moreno, B., & Baez, C. (2010). Factores y riesgos psicosociales, medidas y buenas prácticas, (APRIL 2013), 189. Retrieved from <http://www.insht.es/InshtWeb/Contenidos/Documentacion/PUBLICACIONES PROFESIONALES/factores riesgos psico.pdf>
- Moreno Jiménez, B. (2012). Factores y riesgos laborales psicosociales: conceptualización, historia y cambios actuales. *Medicina y Seguridad Del Trabajo*, 57, 4–19. <https://doi.org/10.4321/s0465-546x2011000500002>
- Mosquera, R., Castrillón, O. D., & Parra, L. (2019). Aplicación del modelo híbrido k-nearest neighborsSupport Vector Machine para la predicción del riesgo psicosocial en docentes de colegios públicos colombianos. *17th LACCEI International Multi-Conference for Engineering, Education, and Technology*.
- Mueller, A., & Guido, S. (2016). *Introduction to Machine Learning with Python (First)*. United States of America: O'Reilly Media. Retrieved from <https://www.oreilly.com>

- Palma, J., & Marín, R. (2008). *INTELIGENCIA ARTIFICIAL Técnicas, métodos y aplicaciones* (First). Madrid: McGraw-Hill. Retrieved from https://kupdf.net/download/inteligencia-artificial-m-eacute-todos-t-eacute-ncias-y-aplicaciones_586feab36454a7362f35c098_pdf
- Peiró, J. (2004). El sistema de trabajo y sus implicaciones para la prevención de los riesgos psicosociales en el trabajo, *3*(2), 179–186.
- Peiro, J. M., & Rodriguez-Molina, I. (2008). Work stress, leadership and organizational health. *Papeles Del Psicologo*, *29*(1), 68–82. Retrieved from <http://www.scopus.com/inward/record.url?eid=2-s2.0-53849084810&partnerID=40&md5=fc80f008b33da337bfd674503028b493>
- Pérez Bilbao, J., & Nogareda Cuixart, C. (2012). NTP 926 Factores psicosociales: metodología de evaluación, 1–6. Retrieved from <http://www.insht.es/InshtWeb/Contenidos/Documentacion/NTP/NTP/926a937/926w.pdf>
- Ponce, P. (2010). *Inteligencia Artificial* (1ra ed.). Alfaomega.
- Quick, J., Macik-Frey, M., & Nelson, D. (2017). Job Stress. *Encyclopedia of Applied Psychology*, (December 2015), 1–8. <https://doi.org/10.1016/B978-0-12-809324-5.05616-9>
- Raschka, S., & Mirjalili, V. (2017). *Python Machine Learning* (Second). Birmingham B3 2PB, UK.: Packt Publishing Ltd. Retrieved from <https://www.packtpub.com/>
- Russell, S., & Norvig, P. (2004). *Inteligencia Artificial: Un enfoque moderno* (Second). Madrid: Pearson Educación S.A.
- Salanova, M., & Llorens, S. (2008). Sobre el concepto de Burnout: su estado actual. *Papeles Del Psicologo*, *29*(1), 59–67.
- Sarkar, D., Bali, R., & Sharma, T. (2018). *Practical Machine Learning with Python* (First). Bangalore. <https://doi.org/10.1007/978-1-4842-3207-1>
- Sastre, M., & Aguilar, E. (2003). *Dirección de recursos humanos. Un enfoque estratégico*. Madrid: McGraw-Hill.

- Saunders, J. (2019). The fourth industrial revolution and social innovation in the work place. *Annals of the New York Academy of Sciences*, 316(1), 549–552. <https://doi.org/10.1111/j.1749-6632.1979.tb29497.x>
- Saxena, R. (2016). KNN Classifier, Introduction to K-Nearest Neighbor Algorithm. Retrieved from <https://dataaspirant.com/k-nearest-neighbor-classifier-intro/>
- Schneider, E., & Irastorza, X. (2011). *OSH in figures: Occupational safety and health in the transport sector. Labour*. European Agency for Safety and Health at Work.
- Shah, D. (2016). *Machine Learning*. Boston, USA. Retrieved from <https://professionalprograms.mit.edu/es/programa-online-machine-learning/>
- Shi, R., & NGan, K. N. (2014). Jaccard index compensation for object segmentation evaluation. *IEEE*. Retrieved from <https://scihub.tw/10.1109/ICIP.2014.7025904>
- Shmueli, G., Bruce, P., Gedeck, P., & Patel, N. (2020). *DATA MINING FOR BUSINESS ANALYTICS* (First). Hoboken: Wiley. Retrieved from <https://www.wiley.com/en-ec/Data+Mining+for+Business+Analytics%3A+Concepts%2C+Techniques+and+Applications+in+Python-p-9781119549864>
- Siegrist, J. (1996). Adverse health effects of high effort low reward conditions. *Journal Occupational Health Psychology*, 1, 27–41.
- Swamynathan, M. (2019). *Mastering Machine Learning with Python in Six Steps* (Second). Bangalore: Springer. <https://doi.org/10.1007/978-1-4842-4947-5>
- Tennant, C. (2001). Work-related stress and depressive disorders. *Journal of Psychosomatic Research*, 51, 697–704.
- Unda, S., Uribe, F., Jurado, S., García, M., Tovalín, H., & Juárez, A. (2016). Elaboración de una escala para valorar los factores de riesgo psicosocial en el trabajo de profesores universitarios. *Journal of Work and Organizational Psychology*, 32(2), 67–74. <https://doi.org/10.1016/j.rpto.2016.04.004>
- Van den Heuvel, S. G., Bakhuis Roozebom, M. C., Eekhout, I., & Venema, A. (2018). Gestión de los riesgos psicosociales en los lugares de trabajo europeos :

datos de la segunda encuesta europea de empresas sobre riesgos nuevos y emergentes (ESENER-2). *Agencia Europea Para La Seguridad y La Salud En El Trabajo (EU-OSHA)*, 1–10.

Van den Heuvel, S., Van der Zwaan, L., Van Dam, L., Oude-Hengel, K., Eekhout, I., Van Emmerik, M., ... Paweli, C. (2017). Estimación del coste de los accidentes y los problemas de salud en el trabajo, 7. <https://doi.org/10.2802/82279>

Vega, S. (2001). NTP 604 : Riesgo psicosocial : el modelo demanda-control-apoyo social (II). *Instituto Nacional de Seguridad e Higiene En El Trabajo*, (Ii), 1–8. <https://doi.org/10.1016/j.jcp.2007.02.012>.Condensed

WHO. (2018). *Global Status Report On Road Safety 2018*.

ANEXOS

Anexo 1: Cuestionario de riesgos psicosociales

Sociodemográficas y laborales

	Hombre	Mujer			
(1) Sexo					
	Soltero	Casado	Unión libre	Divorciado	Otro
(2) Estado civil					
	De 18 a 30 años	31 a 40 años	41 a 50 años	51 a 65 años	Más de 65 años
(3) Edad					
	No tiene	De 1 a 3	De 4 a 6	Más de 7	
(4) Cargas familiares					
	Básica	Bachiller	Tercer nivel	Cuarto nivel	
(5) Nivel de educación					
	Si	No			
(6) Labora exclusivamente como conductor					
(7) Es propietario del Bus que conduce					
(8) Es afiliado al seguro social (IESS)					
	De 1 a 4 años	De 5 a 9 años	De 10 a 19 años	Más de 20	
(9) Cuantos años de experiencia tiene como conductor de Bus					
	1 vez	2 veces	3 veces	Más de 4	Nunca
(10) Ha tenido algún accidente de tránsito en el 2017					
(11) Ha tenido algún accidente de tránsito en el 2018					

Riesgos psicosociales laborales

Tiempo de trabajo

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(1) Trabajo en sábados				
(2) Trabajo en domingos y festivos				
(3) Tiempo de descanso semanal				
(4) Compatibilidad vida laboral - vida social				

Autonomía temporal

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(5) Posibilidad de atender asuntos personales				
(6) Distribución de pausas reglamentarias				
(7) Adopción de pausas no reglamentarias				
(8) Determinación del ritmo				

Autonomía decisional

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(9) Actividades y tareas				
(10) Distribución de tareas				
(11) Distribución del espacio de trabajo				
(12) Métodos, procedimientos y protocolos				
(13) Cantidad de trabajo				
(14) Calidad del trabajo				
(15) Resolución de incidencias				
(16) Distribución turnos				

Presiones de tiempos

	Siempre o	A menudo	A veces	Nunca o
--	-----------	----------	---------	---------

	casi siempre			casi nunca
(17) Tiempo asignado a la tarea				
(18) Tiempo de trabajo con rapidez				
(19) Aceleración del ritmo de trabajo				

Esfuerzo de atención

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(20) Tiempo de atención				
(21) Intensidad de la atención				
(22) Atención múltiples tareas				
(23) Interrupciones				
(24) Efecto de las interrupciones				
(25) Previsibilidad de las tareas				

Cantidad y dificultad de la tarea

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(26) Cantidad de trabajo				
(27) Dificultad del trabajo				
(28) Necesidad de ayuda				
(29) Trabajo fuera del horario habitual				

Exigencias cognitivas

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(30) Requerimientos de aprendizajes				
(31) Requerimientos de adaptación				
(32) Requerimientos de iniciativas				
(33) Requerimientos de memorización				
(34) Requerimientos de creatividad				

Exigencias emocionales

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(35) Requerimientos de trato con personas				
(36) Ocultación de emociones ante superiores				
(37) Ocultación de emociones ante subordinados				
(38) Ocultación de emociones ante compañeros				
(39) Ocultación de emociones ante clientes				
(40) Exposición a situaciones de impacto emocional				
(41) Demandas de respuesta emocional				

Variedad / Contenido

	No	A veces	Bastante	Mucho
(42) Trabajo rutinario				

	Mucho	Bastante	Poco	Nada
(43) Sentido del trabajo				

	No es muy importante	Es importante	Es muy importante	No lo sé
(44) Contribución del trabajo				

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca	No tengo, no trato
(45) Reconocimiento del trabajo por superiores					
(46) Reconocimiento del trabajo por compañeros					
(47) Reconocimiento del trabajo por clientes					
(48) Reconocimiento del trabajo por familia					

Participación / Supervisión

	Puedo decidir	Se me consulta	Solo recibo información	Ninguna participación
(49) Participación en la introducción de cambios en equipos y materiales				
(50) Participación en la introducción de métodos de trabajo				
(51) Participación en el lanzamiento de nuevos productos				
(52) Participación en la reorganización de áreas de trabajo				
(53) Participación en introducción de cambios en la dirección				
(54) Participación en contrataciones de personal				
(55) Participación en la elaboración de normas de trabajo				

	No interviene	Insuficiente	Adecuada	Excesiva
(56) Supervisión sobre los métodos				
(57) Supervisión sobre la planificación				
(58) Supervisión sobre el ritmo				
(59) Supervisión sobre la calidad				

Interés por el trabajador / Compensación

	No hay información	Insuficiente	Es adecuada
(60) Información sobre la formación			
(61) Información sobre las posibilidades de promoción			
(62) Información sobre requisitos para la promoción			
(63) Información sobre la situación de la empresa			

	Adecuada	Regular	Insuficiente	No existe
(64) Facilidades para el desarrollo profesional				

	Muy adecuada	Suficiente	Insuficiente en algunos casos	Totalmente insuficiente
(65) Valoración de la formación				
(66) Equilibrio entre esfuerzo y recompensas				

	Muy satisfecho	Satisfecho	Insatisfecho	Muy insatisfecho
(67) Satisfacción con el salario				

Desempeño de rol

	Muy clara	Clara	Poco clara	Nada clara
(68) Especificaciones de los cometidos				
(69) Especificaciones de los procedimientos				
(70) Especificaciones de la cantidad de trabajo				
(71) Especificaciones de la calidad de trabajo				
(72) Especificaciones de los tiempos de trabajo				
(73) Especificaciones de la responsabilidad del puesto				

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca
(74) Tareas irrealizables				
(75) Procedimientos de trabajo incompatibles con objetivos				
(76) Conflictos morales				
(77) Instrucciones contradictorias				
(78) Asignación de tareas que exceden el cometido del puesto				

Relaciones y apoyo social

	Siempre o casi siempre	A menudo	A veces	Nunca o casi nunca	No tengo, no hay otras personas
(79) Apoyo social e instrumental de tus superiores					
(80) Apoyo social e instrumental de tus compañeros					

(81) Apoyo social e instrumental de tus subordinados					
(82) Apoyo social e instrumental de otras personas que trabajan en la empresa					
	Buenas	Regulares	Malas	No tengo compañeros	
(83) Calidad de las relaciones					
	Raras veces	Con frecuencia	Constantemente	No existen	
(84) Exposición a conflictos interpersonales					
(85) Exposición a violencia física					
(86) Exposición a violencia psicológica					
(87) Exposición a acoso sexual					
	Deja que sean los implicados quienes solucionen el tema	Pide a los mandos de los afectados que traten de buscar una solución al problema	Tiene establecido un procedimiento formal de actuación	No lo sé	
(88) Gestión de la empresa de las situaciones de conflicto					
	Siempre o casi siempre	A menudo	A veces	Nunca	
(89) Exposición a discriminación					

Anexo 2: Cuestionario organización y gestión de riesgos psicosociales

	Si	No
(1) Dispone de unidad de gestión de riesgos		
(2) Dispone de un delegado de SST.		
(3) Dispone de un protocolo para tratar el estrés		
(4) Dispone de un protocolo para tratar el acoso laboral		
(5) Dispone de un procedimiento para tratar los riesgos psicosociales		

	Nunca	Ocasionalmente	Frecuentemente	Siempre
(6) Se aplican los procedimientos de gestión de recursos humanos				
(7) Los problemas de SST se tratan en reuniones de alto nivel				

Anexo 3: Información del transporte de buses urbanos requerida de la ANT

Número de unidades

Buses de transporte urbano	Unidades

Siniestros de transporte años 2017 y 2018

N°	Presuntas causas	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC


Tipología de siniestros años 2017 y 2018

Tipología	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC

Número de infracciones

Buses de transporte urbano	Infracciones registradas

Anexo 4: Visualización del Árbol de Decisión



Continúa...

