

**Escuela Superior Politécnica del Litoral**

**Facultad de Ciencias Naturales y Matemáticas**

Control inteligente de incidentes industriales en empresa de Gas Licuado de Petróleo (GLP) mediante estadísticas multivariantes y aprendizaje automático.

**Proyecto Integrador**

Previo la obtención del Título de:

**Ingeniero Estadístico**

Presentado por:

- Wilson William León del Valle
- John Jairo Borbor Mieles

Guayaquil - Ecuador

Año: 2024



## Dedicatoria

---

El presente proyecto lo dedico a Dios quien me dio la sabiduría necesaria y a mi familia quien fue un pilar fundamental de apoyo e impulso para lograr esta meta (William León).

Le dedico el presente proyecto a Dios por darme la fuerza, la paciencia y la sabiduría para completar este trabajo. A mi madre y a mi abuela, por su amor incondicional y que han sido un pilar en mi vida. A mi familia. A mis profesores. A mis amigos, por su compañía incondicional tanto del colegio como de la selección de baloncesto de ESPOL. A las instituciones, tanto de mi etapa colegial y universitaria (John Borbor).

## **Agradecimientos**

---

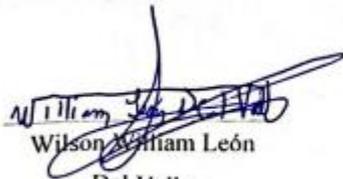
**A Dios que escuchó cada una de las oraciones de mamá, para mi madre que lucho incansablemente por verme cumplir mis metas y siempre me apoyo en todo, a mi hermana por ser un ejemplo de lucha incansable y sus consejos que siempre me guiaron a cada día ser mejor y no rendirme por más duro que fuera el camino, a mi compañera de vida que fue mi apoyo en los momentos más difíciles de este camino (William León).**

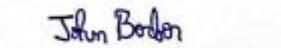
**Mi más sincero agradecimiento a Dios por darme la fuerza, la paciencia y la sabiduría para completar este trabajo. A mi madre y a mi abuela. A mi familia. A mis profesores. A mis amigos, por su compañía incondicional tanto del colegio como de la selección de baloncesto de ESPOL. A las instituciones, tanto de mi etapa colegial y universitaria. A todos aquellos que contribuyeron a la realización de esta tesis. Sin ustedes, este logro no habría sido posible (John Borbor).**

## Declaración Expresa

---

“Los derechos de titularidad y explotación, nos corresponde conforme al reglamento de propiedad intelectual de la institución; *Wilson William León del Valle* y *John Jairo Borbor Mieles* y damos nuestro consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual”

  
Wilson William León  
Del Valle

  
John Jairo Borbor Mieles

## **Evaluadores**

---

**Ph. D. García Bustos Sandra Lorena**

Profesor de Materia

---

**M. Sc. Bauz Olvera Sergio Alex**

Tutor de proyecto

## Resumen

El proyecto propone un sistema de control inteligente de incidentes industriales en una empresa de Gas Licuado de Petróleo (GLP), con el objetivo de identificar y prevenir incidentes antes de que se conviertan en amenazas reales. Se justifica por la alta peligrosidad del GLP y la necesidad de mejorar la seguridad en su manejo y transporte. En el desarrollo del proyecto, se utilizaron técnicas estadísticas multivariantes y algoritmos de aprendizaje automático. Los datos se recopilaron mediante plataformas de geolocalización y se analizaron con herramientas como RStudio. Se realizó un análisis exploratorio y se construyeron modelos predictivos mediante árboles de decisión.

Los resultados muestran que los incidentes más frecuentes en las unidades de transporte fueron exceso de velocidad y paradas en lugares no seguros, destacando diferencias entre los colectivos de distribución y abastecimiento. El modelo predictivo permitió anticipar situaciones de riesgo, mejorando la seguridad vial.

Se concluye que el uso de modelos predictivos y técnicas de control inteligente ha mejorado significativamente la gestión de riesgos en la empresa. Se recomienda mantener el monitoreo constante de los indicadores y capacitar a los trabajadores para asegurar la efectividad de las medidas implementadas.

**Palabras clave:** seguridad vial, Gas Licuado de Petróleo, control inteligente, aprendizaje automático.

## **Abstract**

The project proposes an intelligent control system for industrial incidents in a Liquefied Petroleum Gas (LPG) company, with the aim of identifying and preventing incidents before they become real threats. It is justified by the high danger of LPG and the need to improve safety in its handling and transportation. In the development of the project, multivariate statistical techniques and machine learning algorithms were used. Data was collected using geolocation platforms and analyzed with tools such as RStudio. An exploratory analysis was carried out and predictive models were built using decision trees.

The results show that the most frequent incidents in the transport units were excessive speed and stops in unsafe places, highlighting differences between the distribution and supply groups. The predictive model made it possible to anticipate risk situations, improving road safety.

It is concluded that the use of predictive models and intelligent control techniques has significantly improved risk management in the company. It is recommended to maintain constant monitoring of the indicators and train workers to ensure the effectiveness of the implemented measures.

**Keywords:** road safety, Liquefied Petroleum Gas, intelligent control, machine learning.

## Índice general

Resumen .....	i
Abstract .....	ii
Índice de figuras .....	iv
Índice de tablas.....	vi
Abreviaturas .....	vii
1.1    Introducción.....	1
1.2    Descripción del Problema.....	2
1.3    Justificación del Problema.....	3
1.4    Objetivos.....	4
1.4.1    Objetivo general.....	4
1.4.2    Objetivos específicos .....	4
1.5    Marco teórico.....	4
1.5.1    Industria del Gas Licuado de Petróleo .....	4
1.5.2    Gestión de incidentes industriales.....	5
1.5.3    Seguridad industrial y control de incidentes.....	5
1.5.4    Estadísticas multivariantes.....	7
1.5.4.1    Análisis de componentes principales (ACP). .....	7
1.5.4.2    Regresión Lineal Multivariante. ....	7
1.5.5    Aprendizaje automático (Machine Learning) .....	8
1.5.6    Estudios previos sobre control de incidentes industriales .....	9
1.5.7    Tendencias actuales en el uso de tecnología para la gestión de riesgos .....	9
1.5.8    Herramientas y plataformas de aprendizaje automático .....	10
1.5.9    Sistemas inteligentes en el control de riesgos .....	12

1.5.10	<i>Mejoras en la seguridad industrial</i> .....	13
2.1.	Recopilación de datos .....	15
2.2.	Plataformas de apoyo para la recopilación de registros de alertas .....	15
2.2.1.	<i>TRACKLINK</i> .....	15
2.2.2.	<i>ONTRACK</i> .....	17
2.3.	Depuración y/o limpieza de registros .....	18
2.4.	Análisis exploratorio univariante.....	19
2.5.	Creación de base de datos adicionales.....	21
2.6.	Implementación de árboles de decisión.....	24
2.7.	Implementación del Sistema de Indicadores .....	26
3.	Resultados y análisis .....	28
4.1	Conclusiones y recomendaciones .....	49
4.1.1	<i>Conclusiones</i> .....	49
4.1.2	<i>Recomendaciones</i> .....	50
	Referencias.....	51

### **Índice de figuras**

Figura 3.1 .....	28
Frecuencia de incumplimientos del periodo enero a diciembre colectivo de distribución. ....	28
Figura 3.2 .....	29
Frecuencia de incumplimientos del periodo enero a diciembre colectivo de abastecimiento. ....	29
Figura 3.3 .....	30
Frecuencia de incumplimientos del periodo enero a diciembre colectivo de abastecimiento ontrack. .....	30
Figura 3.4 .....	31

Frecuencia de incumplimientos del periodo enero a diciembre colectivo de distribución ontrack. ...	31
Figura 3.5 .....	32
Evolución Semanal de incumplimientos del grupo de Abastecimiento periodo enero a diciembre. .....	32
Figura 3.6 .....	33
Evolución Semanal de los incumplimientos del grupo de Distribución periodo enero a diciembre. .....	33
Figura 3.7 .....	34
Evolución Semanal de los incumplimientos de pausas activas periodo enero a diciembre. ....	34
Figura 3.8 .....	37
Gráficos de dispersión para los principales pares de variables de la base de datos de Abastecimiento. ....	37
Figura 3.9 .....	38
Biplot de Análisis de Componentes Principales (Abastecimiento).....	38
Figura 3.10 .....	39
Árbol de decisión con la predicción de la tasa promedio de excesos de velocidad (Abastecimiento). .....	39
Figura 3.11 .....	40
Propuesta de Dashboard de control para los excesos de velocidad colectivo de Abastecimiento. ..	40
Figura 3.12 .....	43
Gráficos de dispersión para los principales pares de variables de la base de datos de Distribución.....	43
Figura 3.13 .....	44
Biplot de Análisis de Componentes Principales (Distribución).....	44
Figura 3.14 .....	45
Árbol de decisión con la predicción de la tasa promedio de excesos de velocidad (Distirbución). 45	
Figura 3.15 .....	46
Propuesta de Dashboard de control para los excesos de velocidad colectivo de Distribución. ....	46

## Índice de tablas

Tabla 3.1.....	35
Resumen de las variables principales de alto riesgo para el colectivo de Abastecimiento.....	35
Tabla 3.2.....	41
Resumen de las variables principales consideradas de alto riesgo para el colectivo de Distribución. .....	41

## **Abreviaturas**

ESPOL: Escuela Superior Politécnica del Litoral

GLP: Gas Licuado de Petróleo

ACP: Análisis de Componentes Principales

ANT: Agencia Nacional de Tránsito

SEMMAQ SAC: empresa internacional que brinda servicio de hidrocarburo, gas licuado, gas natural, instalación de tanques, entre otros de calidad.

IBM: International Business Machines

REBA: Rapid Entire Body Assessment

OCRA: Occupational Repetitive Action

ISTAS: Instituto Sindical de Trabajo, Ambiente y Salud

FMS: Fleet Management System

GPS: Sistema de Posicionamiento Global

IoT: Internet of Things

PDF: Portable Document Format

KPI: Key Performance Indicator

IFV: Índice de frecuencia vehicular

GIS: Gestor de Indicadores de Seguridad

ANOVA: Analysis of Variance

# Capítulo 1

## 1.1 Introducción

La industria del Gas Licuado de Petróleo (GLP) emerge como un actor silencioso pero que es importante en la ecuación energética global. Este producto es utilizado en el hogar porque evita que las ollas y calderos se infiltren con humo no deseado, además que se puede encontrar un gran número de electrodomésticos que operan con este gas; además en el transporte, es considerado como uno de los combustible principales de los vehículos; en el comercio es adoptado en hoteles, restaurante, entre otros comercios debido a su gran variedad de ventajas ya que tiene aplicaciones en áreas de generadores de energía, calefacción y otras funciones adicionales; en la construcción, debido a que se optan por el uso de maquinarias que funcionan con él ya que es más beneficioso comparado con otras opciones; y en la recreación, ya que se destaca por preservar la calidad del aire reduciendo así las emisiones de dióxido de carbono (SEMMAQ SAC, 2024).

El manejo del Gas Licuado de Petróleo (GLP) implica riesgos debido a que es un recurso inflamable y volátil, por lo que es importante la seguridad en todo su proceso, es decir, en su producción, almacenamiento, distribución y comercialización.

El manejo inapropiado de este recurso deriva en incidentes graves, desde pequeñas fugas hasta explosiones catastróficas, en donde pueden salir afectadas personas, infraestructuras e inclusive el medio ambiente. Debido a esto, las empresas que se dedican a su comercialización deben tener sistemas de control y prevención de riesgos, que además de identificar riesgos potenciales, también puedan predecir los posibles eventos que puedan ocurrir.

Según la página de noticias EL GAS, el Reglamento de Seguridad para Instalaciones y Transporte de GLP de la Ley Orgánica de Hidrocarburos señala algunos requisitos que los camiones cisterna y otros vehículos deben seguir para el transporte de este recurso, estos son:

- Contar con autorización expedida por la Dirección General de Hidrocarburos, del Ministerio de Energía y Minas, además de estar registradas.
- Contar con extintores de polvo seco tipo ABC, de 9 kilogramos.
- Cargar la capacidad máxima de cilindros que le corresponda.
- Los conductores y ayudantes de carga no pueden fumar durante el transporte ni dejar que otras personas lo hagan alrededor del vehículo durante la descarga o parqueo de los mismos.

En este proyecto se busca proponer un sistema de control inteligente de incidentes industriales en una empresa comercializadora de GLP mediante el uso de técnicas estadísticas multivariantes y aprendizaje automático con el objetivo de desarrollar una herramienta que sea capaz de identificar, predecir y disminuir los incidentes antes de que sean amenazas reales.

## **1.2 Descripción del Problema**

En Ecuador, el Gas Licuado de Petróleo (GLP) se transporta principalmente por carretera, lo que hace que la seguridad vial sea una preocupación crítica. Las carreteras pueden no estar siempre en las mejores condiciones. Según estadísticas de la Agencia Nacional de Tránsito (ANT), los accidentes de tránsito en carreteras ecuatorianas han aumentado en los últimos años dando un incremento significativo en la tasa de mortalidad, que alcanzó los 12.25 fallecidos por cada 100,000 habitantes en 2022, en comparación con 12.00 en 2021, y el transporte de Gas Licuado de Petróleo (GLP) involucra un riesgo adicional debido a la peligrosidad del producto en caso de accidente.

Las provincias con mayor número de accidentes y víctimas son Guayas, Pichincha, y Los Ríos, que concentran más del 50% de las muertes.

En los primeros seis meses de 2024, se registraron 10,592 siniestros de tránsito a nivel nacional,

y un 43% de ellos involucraron automóviles, mientras que el 23% involucró camiones, estos accidentes causados por distracción, exceso de velocidad y consumo de alcohol (Instituto Nacional de Estadística y Censos. (2024.) *Resultados de siniestros de tránsito al I trimestre de 2024*. Agencia Nacional de Tránsito).

El transporte de este producto, debido a su naturaleza inflamable, agrava las consecuencias de estos accidentes, aumentando el potencial de explosiones y víctimas fatales. En Quito, se atendieron 272 emergencias por fugas de GLP en 2022, y algunos incidentes incluyeron explosiones y daños estructurales (Mantilla & Pazan, 2022).

A nivel nacional se reparten un total de 200,000 tanques diarios para atender el consumo en los hogares del país (Eppetroecuador, 2024). En 2021, las muertes en plataformas petrolíferas aumentaron un 10% con respecto al 2020 (Tawney et al., 2023).

Por tanto, es indispensable contar con indicadores de seguridad vial y física en la industria del Gas Licuado de Petróleo (GLP) por varias razones, especialmente en el contexto de los crecientes accidentes de tránsito en Ecuador.

### **1.3 Justificación del Problema**

La necesidad de contar con indicadores de seguridad vial y física en el transporte de Gas Licuado de Petróleo (GLP) es crítica debido a los altos riesgos asociados a su distribución. El incremento en la tasa de accidentes de tránsito y mortalidad, especialmente en provincias como Guayas, Pichincha y Los Ríos, subraya la importancia de mejorar los sistemas de control y prevención. Por otro lado, la creciente demanda de Gas Licuado de Petróleo (GLP), con la distribución diaria de cientos de miles de tanques, hace indispensable el monitoreo de condiciones de seguridad para proteger tanto a la población como al entorno. Los indicadores de seguridad permitirán tomar decisiones informadas, minimizar incidentes graves y garantizar la eficiencia y seguridad en la cadena de suministro.

## **1.4 Objetivos**

### ***1.4.1 Objetivo general***

Analizar los incidentes en una compañía comercializadora de Gas Licuado de Petróleo (GLP) a través un producto estadístico computacional basado en modelos de aprendizaje automático para la toma de decisiones basada en datos.

### ***1.4.2 Objetivos específicos***

1. Explorar la calidad de los datos relacionados con los incidentes más frecuentes de seguridad vial para obtener resultados más confiables.
2. Establecer los indicadores más importantes para medir la seguridad vial para la implementación de herramientas que faciliten la toma de decisiones y ayuden a prevenir incidentes en la empresa.
3. Analizar el ajuste de un modelo predictivo y efectivo, mediante la detección de patrones en los datos históricos y prevenir accidentes o riesgos futuros de la empresa.

## **1.5 Marco teórico**

### ***1.5.1 Industria del Gas Licuado de Petróleo***

El Gas Licuado de Petróleo es un combustible que está compuesto principalmente de los hidrocarburos propano y butano, además de otras en menor proporción. Esta se obtiene a partir de la refinación del crudo del petróleo o del proceso de separación del gas natural en los pozos de extracción. Es incoloro e inodoro. El GLP se puede transportar ya sea en cilindros o en tanques estacionarios, y puede ser transportado por mar, ferrocarril, ducto o por carretera (GASNOVA, 2017).

Una ventaja del uso del GLP es que al ser un combustible eficiente y con un poder calórico alto,

nos permite una mejor utilización de la energía, además es un combustible aplicable en el uso doméstico, industrial y el transporte (Enerlogix-Solutions, 2024).

Los riesgos asociados con la operación de empresas de GLP son: el incumplimiento del distanciamiento mínimo, falta de vaporización, falta de sistemas de protección y seguridad, accesorios de conexión en mal estado (Vásconez et al., 2018).

### ***1.5.2 Gestión de incidentes industriales***

Un manejo inadecuado del GLP podría generar riesgos potenciales. Lo que afectaría no sólo la productividad de la empresa, si no también la eficiencia y seguridad del personal. Por lo que es importante conocer y aplicar las mejores prácticas de seguridad en el manejo del GLP (UNIGAS, 2024).

En un estudio de Cavazos-Arroyo, et al. (2014) indican que los daños que son causados por incidentes industriales pueden clasificarse en humanas, al patrimonio, y al medio ambiente. Los daños en los humanos implican principalmente a intoxicaciones. En el patrimonio implican a la pérdida de propiedades. Y, en el medio ambiente implican afectaciones en la fertilidad del suelo y aunque algunos de estos terrenos pasan por un proceso de biorremediación, otros quedan abandonados, en los cultivos (la mayoría comestibles) y en el agua que corre por los canales que son utilizadas para riego y causan contaminación en la producción.

### ***1.5.3 Seguridad industrial y control de incidentes***

La seguridad industrial se refiere al conjunto de normas obligatorias que se enfocan en la prevención y protección de accidentes en el trabajo que produzcan daño tanto a las personas, como a los bienes o al medio ambiente de la empresa. Principalmente su uso se basa en minimizar los accidentes laborales de manera preventiva (EDS Robotics, 2021).

Según un estudio realizado por Espinosa (2018) las actividades de seguridad y control de

incidentes se dividen en cuatro fases de manera cíclica, estas son:

- **Fase de prevención o mitigación:** Esta fase es donde se toman medidas de mitigación que ayuden a reducir o suprimir el riesgo de los empleados, ambiente y propiedad. La principal fase para el manejo de emergencias es la prevención, que además de proteger a las personas, ambiente y activos industriales, también tiene como objetivo reducir costos de respuesta y recuperación.
- **Fase de preparación:** Esta fase consiste en la construcción de la gestión de incidentes para poder reaccionar efectivamente a cualquier riesgo. Esta fase es importante ya que no siempre es posible mitigar los riesgos completamente, por lo que las medidas de preparación nos ayudan a minimizar el impacto de estos. La fase de preparación tiene como objetivo preparar planes de emergencia para salvar vidas y tener opciones de respuesta y recuperación asignando y capacitando al personal para que ayuden en las áreas clave, también identificar recursos que se necesiten en una emergencia.
- **Fase de Respuesta:** Esta fase consiste en aplicar los planes de emergencia para salvar vidas, proteger el medio ambiente y las propiedades. Las principales actividades de respuesta consisten en brindar asistencia de emergencia a las víctimas, restaurar la infraestructura crítica y garantizar la continuidad de los servicios.
- **Fase de Recuperación:** Esta fase tiene como objetivo retomar con normalidad los sistemas y actividades de la empresa, inicia después del incidente. Las actividades que lo constituyen son de manera continua a los planes de respuesta. La fase de restauración puede tomar meses o hasta años ya que es un proceso complejo ya que consiste en restaurar la actividad económica y reconstrucción de las edificaciones.

#### **1.5.4 Estadísticas multivariantes**

Peña (2002) indica que el objetivo del análisis de datos multivariantes consiste en el estudio de varias variables medidas a partir de una población. Además, tiene como objetivo resumir el conjunto de variables en pocas variables, encontrar relaciones o grupos en los datos, clasificar las observaciones y relacionar pares de conjuntos de variables. La estadística multivariante tiene aplicaciones en varias disciplinas como administración de empresas, agricultura, geología, medicina, psicología, entre otras.

Existen varias técnicas comunes para el análisis multivariante como:

**1.5.4.1** Análisis de componentes principales (ACP). Pérez (2004) indica que esta es una técnica que se aplica cuando existe un número elevado de variables cuantitativas y se desea obtener un número menor de estas. El ACP permite describir, de manera sintética, las interrelaciones que existen entre las variables originales mediante las componentes obtenidas. El objetivo de este método es transformar un grupo de variables, llamadas variables originales interrelacionadas, en un nuevo grupo llamado componentes principales, las cuales están in-correlacionadas entre sí.

#### **1.5.4.2 Regresión Lineal Multivariante.**

Según Montero Granados (2016) la regresión lineal multivariante es una técnica que supone que más de una variable tiene influencia o correlación con el valor de variable de respuesta. El modelo espera que su forma sea la siguiente:

$$y_j = b_0 + b_1x_{1j} + b_2x_{2j} + \dots + b_kx_{kj} + \varepsilon_j \quad (1.1)$$

En la ecuación (1.1),

$y$  es la variable de respuesta

$x$  son las variables predictoras

$\varepsilon$  son los residuos que siguen una distribución normal con media igual a 0 y varianza

$\sigma^2$ ,  $b_k$  son los coeficientes de regresión

$j$  es el número de observaciones

$k$  es el número de variables predictoras.

### ***1.5.5 Aprendizaje automático (Machine Learning)***

El aprendizaje automático es un proceso en donde los ordenadores utilizan las redes neuronales para reconocer patrones y renovar la capacidad para identificarlos. Las redes neuronales son modelos inspirados en la estructura y funcionamiento del cerebro humano y están compuestos por neuronas artificiales interconectadas (nodos) organizadas en capas (Hewlett Packard Enterprise, 2024). El aprendizaje automático, también llamado Machine Learning, es una rama de la inteligencia artificial cuyo objetivo es desarrollar algoritmos y técnicas que ayuden a los ordenadores a aprender y mejorar de manera automática mediante la experiencia (Conciliac S.A., 2023).

Algunas de las ventajas del uso del aprendizaje automático en la predicción y control de incidentes son: alertas en tiempo real, reparaciones predictivas, detección de malos funcionamientos, reduce los costos, crea sistemas más seguros (UpKeep, 2024).

Algunos de los algoritmos de aprendizaje automático aplicables son:

- **Clustering:** En el trabajo de Garrido (2017) se menciona que el clustering es una técnica que consiste en dividir los datos en un conjunto de grupos (clústers) donde los datos que estén dentro de un mismo grupo tengan características comunes. Los objetivos del clustering son: desarrollar una clasificación, investigar esquemas conceptuales para agrupar entidades y generar hipótesis. El clustering ayuda a identificar agrupaciones de fallos recurrente en las industrias.
- **Detección de anomalías:** Los algoritmos de detección de anomalías examinan puntos en específico y ayudan a localizar y abordar los problemas antes de que se distribuyan por el sistema, lo que ayuda a reducir costos (Amazon Web Services, 2024). Unos de los algoritmos de detección de anomalías son: Isolation Forest, el cual es una técnica que opera aislando las

anomalías en lugar de perfilar puntos de datos normales (Learn Statistics Easily, 2024). Y Autoencoders, los cuales son un tipo especial de redes neuronales que comprimen de manera eficiente los datos de entrada y sus características esenciales, para luego reconstruir la entrada principal por medio de esta representación comprimida (IBM, 2023).

### ***1.5.6 Estudios previos sobre control de incidentes industriales***

Según un reporte de Informe 1468-19-OS/D.S R (Osinermin) en Perú se registraron 213 accidentes durante el periodo del año 2016 al año 2018 en los que se encuentran involucrados vehículos distribuidores de GLP a granel, camiones cisterna o camiones pick up, camioneta baranda y camiones de transporte de GLP en cilindros, es decir que durante cada año se presentaron cerca de 71 accidentes.

Según Ruiz Rojas, Rafael (2020) se debe contar con un plan de contingencia para la gestión de G.L.P., que contemple un incremento en la posibilidad de explosiones e incendios, los cuales podrían provocar impactos ambientales tanto biológicos como no biológicos además de que se debe elaborar un plan de manejo para los riesgos ambientales que se detecten en la práctica, con la finalidad de definir las medidas preventivas y correctivas en el sector dedicado al comercio de G.L.P.

Esta investigación resulta de gran relevancia al contribuir a la disminución de los incidentes provocados en la manipulación, envasado y transporte de G.L.P. ya que aumenta la confianza necesaria para que cada colaborador incluyendo a los transportistas pueda cumplir con sus labores. (Ruiz Rojas Rafael, 2020)

### ***1.5.7 Tendencias actuales en el uso de tecnología para la gestión de riesgos***

Según lo señalado por Lugo (2012, p. 12), la ciencia y la tecnología constituyen un pilar fundamental en el desarrollo social que se ve favorecido por la investigación, ya que esta es fundamental para adquirir comprensión de la realidad y establecer objetivos claros que contribuyen

involucrar a la ciudadanía en la ciencia y la tecnología, de esta manera generar entornos propicios de reflexión, intercambio y construcción colectiva con aspectos de gran relevancia para ellos y así lograr fortalecer una cultura científica y tecnológica a nivel nacional.

Pontarolo (2018) comprobó que al implementar un sistema de seguridad y salud en el trabajo se obtuvo una disminución de los accidentes laborales, además de que el capacitar a los empleados sobre este tema fomenta un ambiente de integración y preocupación mutua, lo que contribuye a la definición de acciones destinadas a mejorar la seguridad laboral. Las tecnologías 4.0 contribuyen a fomentar la salud y seguridad de los trabajadores y están surgiendo como un importante espacio de estudio (Badri et al,2018). Actualmente, las empresas y organizaciones están experimentando un proceso de cambio promovido por el progreso y la integración de las tecnologías 4.0. Según Cabuya (2018), se observa cómo las organizaciones de hoy en día enfrentan desafíos significativos derivados de la revolución tecnológica y el constante cambio, una realidad que fomenta la comprensión y el desarrollo de estrategias para adaptarse a la cuarta revolución industrial.

#### ***1.5.8 Herramientas y plataformas de aprendizaje automático***

Según (Contreras Contreras, Dulcé-Moreno, 2019), durante la fase de análisis cuando se identifiquen requisitos funcionales que sugieren que el cluster-CV2 debería abordarse de manera no supervisada y el usuario no tiene conocimiento previo sobre el número de grupos  $k$  a los que atribuir las muestras la identificación de los datos se lleva a cabo calculando la matriz de distancias euclidianas y luego se procesa utilizando operadores morfológicos en visión computacional.

Las muestras que presenten superposición entre sí necesitan ser corregidas mediante la propagación y dispersión en el espacio de proyección lineal.

Las redes neuronales artificiales son una parte esencial de las técnicas de aprendizaje automático (Machine Learning), que permiten a los sistemas aprender y tomar decisiones basadas en datos sin

requerir programación específica para cada tarea. Un modelo de aprendizaje automático identifica patrones en los datos y utiliza esos patrones para hacer predicciones o tomar decisiones. Este proceso imita la forma en que los humanos aprenden a partir de la experiencia para reconocer patrones y mejorar su desempeño.

El funcionamiento de un modelo de Machine Learning implica el uso de grandes conjuntos de datos, a partir de los cuales el sistema identifica relaciones y patrones que luego utiliza para construir un modelo predictivo. Este modelo se ajusta a medida que recibe nueva información, con el fin de mejorar su precisión. Según el tipo de datos y el problema a resolver, existen dos enfoques principales: el aprendizaje supervisado y el aprendizaje no supervisado.

En el aprendizaje supervisado, los modelos trabajan con datos previamente etiquetados, es decir, cada entrada de datos viene acompañada de su respuesta correcta o etiqueta. El sistema analiza las relaciones entre estas entradas y salidas para aprender a hacer predicciones. Un ejemplo claro es el uso de redes neuronales en el análisis de imágenes médicas, donde se entrena a los modelos con imágenes ya clasificadas para que aprendan a identificar patrones que pueden indicar diferentes enfermedades (Amazon Web Services, 2024).

Por otro lado, en el aprendizaje no supervisado, los datos no están etiquetados, y el modelo debe descubrir patrones por sí solo. Un ejemplo es el análisis de agrupamiento (clustering), donde el sistema organiza los datos en grupos basados en similitudes sin haber recibido indicaciones previas sobre las categorías existentes. Este tipo de aprendizaje es común en marketing, donde las empresas lo usan para segmentar a los consumidores según su comportamiento en línea y hábitos de compra, optimizando así las estrategias de publicidad (Amazon Web Services, 2024).

Las redes neuronales representan una de las aplicaciones más avanzadas del Machine Learning. Estas redes están formadas por múltiples capas de neuronas artificiales que trabajan en conjunto para procesar información, similar a cómo lo hacen las neuronas en el cerebro humano. A través de ajustes continuos en las conexiones entre estas neuronas, las redes neuronales son capaces de mejorar su rendimiento a medida que procesan más datos. Esta capacidad de aprendizaje continuo las convierte en herramientas muy eficaces para resolver problemas complejos y adaptarse a nuevas situaciones. Por este motivo, su uso se ha extendido en áreas como la medicina, el marketing y las finanzas, donde facilitan la toma de decisiones y la automatización de tareas complejas (Amazon Web Services, 2024).

Los enfoques de aprendizaje supervisado y no supervisado ofrecen maneras complementarias de resolver problemas en campos tan diversos como el análisis de imágenes médicas o la segmentación de mercados. Con el continuo avance de estas tecnologías, su impacto en nuestra vida cotidiana y en la innovación tecnológica seguirá creciendo de manera significativa (Amazon Web Services, 2024).

### ***1.5.9 Sistemas inteligentes en el control de riesgos***

Da Silva y colegas (2019) sugieren que las posibilidades de favorecer el crecimiento de industrias inteligentes están en crecimiento con la transformación de los sistemas de producción hacia modelos cuyo objetivo es maximizar la eficiencia junto a la competitividad, por eso surge la necesidad de adoptar tecnologías y procesos más eficientes, mejorar los estándares de calidad, reducir costos y fomentar la innovación tecnológica.

Además, la principal premisa de este innovador enfoque de manufactura es favorecer la evolución de los procedimientos industriales vigentes así obtener personal más astuto y capaz de adaptarse, con un uso eficiente de los recursos.

### **1.5.10 Mejoras en la seguridad industrial**

Según Montero Maguiña Juan (2023) para proteger, preservar, mantener y promover la cultura de prevención de riesgos laborales para el personal en general que esta ligada a servicios de comercialización de G.L.P. se necesita la colaboración de los empleados que apliquen técnicas de mejoras continuas y así evitar daños a la salud.

Según (Manrique y Otero,2019) titulado "Propuesta de mejora para la mejora de la eficiencia". reducir el grado de riesgo disergonómico y psicosocial en los empleos del sector de la administración de recursos humanos señalaron que en la compañía de investigación existen empresas con elevadas cifras de riesgo disergonómico y psicosocial en las tareas laborales. Además, se llevó a cabo el cuestionario que señala las condiciones de las condiciones de trabajo de forma objetiva, luego se emplearon técnicas como REBA y OCRA, listado de verificación, estudio Lumínico e ISTAS 21, que determinan el riesgo para llevar a cabo acciones propuestas de mejora que reduzcan el riesgo, como definir la estrategia de seguridad jurídica mobiliario ergonómico, diseños de utensilios, formación para los trabajadores, un plan de incorporación de personal, lo que produce resultados como la reducción del riesgo en cada uno.

## Capítulo 2

## **2. Metodología.**

### **2.1. Recopilación de datos**

Se recopiló información histórica relacionada con incidentes de seguridad vial y física en la empresa de GLP. Los datos incluyeron variables como localización geográfica, categoría de incidente, respuesta de validación de la alerta, nombre del conductor, nombre del monitorista encargado de validar la alerta, entre otras.

### **2.2. Plataformas de apoyo para la recopilación de registros de alertas**

Además se contó con la ayuda de dos plataformas de seguimiento y geolocalización satelital (Tracklink) que durante un periodo de seis meses diariamente recopilaban los registros resultantes de alertas generadas por dichas plataformas, una de estas lleva el control de velocidad a través de parametrizaciones para fijar estos límites y también verifica si el vehículo se encuentra detenido en una zona no permitida puesto que se parametrizan zonas seguras de detención por la importancia del producto que se transporta, la segunda plataforma refuerza estas verificaciones a través de validación de cámaras OnTrack a bordo de las unidades además de ayudar al control de distracciones por parte del conductor tales como uso de telefonía celular, mal uso o no utilización del cinturón de seguridad, somnolencias, distracciones que conlleven a perder la concentración de la vía.

#### **2.2.1. TRACKLINK**

Por su parte se puede decir que la aplicación TrackLink se presenta como una innovadora herramienta tecnológica destinada a la gestión, monitoreo y control de flotas en tiempo real. Este tipo de soluciones está dentro del ámbito de los sistemas de gestión de flotas (FMS) y se apoya en tecnologías como el GPS, la telemática y el análisis de datos para optimizar las operaciones logísticas.

TrackLink proporciona a las empresas una vista centralizada del estado y ubicación de sus vehículos, facilitando funciones clave como el monitoreo en tiempo real, la gestión de rutas, la

supervisión del comportamiento al conducir y el control del mantenimiento preventivo de los vehículos. Estas capacidades no solo potencian la eficiencia operativa, sino que también contribuyen a la reducción de costos asociados al consumo de combustible, el tiempo de inactividad y el desgaste de los vehículos.

En el contexto de la transformación digital en la logística, TrackLink se alinea perfectamente con la creciente necesidad de conectividad y análisis de datos. Además, la aplicación incrementa la seguridad al ofrecer alertas instantáneas sobre accidentes, desvíos de ruta y comportamientos inapropiados, como el exceso de velocidad o las frenadas bruscas, lo que protege a los conductores y asegura el cumplimiento de las normativas de transporte.

Particularmente relevante para empresas que manejan grandes flotas, TrackLink facilita la toma de decisiones basadas en datos y promueve operaciones más sostenibles y transparentes. Su implementación incluye la integración con dispositivos de Internet de las cosas (IoT) y plataformas de análisis de datos, lo que permite a las organizaciones mantener su competitividad en un mercado en constante cambio.

TrackLink ofrece la posibilidad de acceder a informes detallados sobre el rendimiento y seguimiento de su flota de transporte. Este proceso se lleva a cabo a través de una plataforma en línea que cuenta con herramientas para personalizar y descargar informes según las necesidades específicas del usuario. Para descargar un informe, primero debe acceder al módulo de Análisis o Informes en su panel de control. Desde allí, podrá seleccionar los parámetros deseados, como un intervalo de tiempo, un vehículo en particular o el tipo de datos que necesita (kilometraje, consumo de combustible, alertas generadas, entre otros). Una vez que haya definido los criterios, la plataforma generará un informe de muestra, que podrá exportar en formatos como Excel o PDF para su posterior análisis. Además, TrackLink le brinda la opción de programar informes recurrentes que se enviarán automáticamente por correo electrónico en intervalos establecidos. Esta funcionalidad resulta especialmente valiosa para los administradores de flotas, ya que asegura un seguimiento continuo y efectivo de las operaciones.

### **2.2.2. ONTRACK**

La aplicación OnTrack se presenta como una innovadora solución para la gestión de tareas, productividad y el logro de objetivos en entornos laborales y logísticos. Este software actúa como una herramienta de gestión de proyectos y rendimiento, con un énfasis notable en la trazabilidad y el seguimiento de actividades. OnTrack es ampliamente utilizado para asignar, supervisar y evaluar las tareas de empleados, conductores y trabajadores de campo.

Uno de sus principales valores radica en la capacidad de ofrecer una visión clara del progreso de las campañas mediante informes en tiempo real, indicadores clave de rendimiento (KPI) y paneles visuales intuitivos. Diseñada para mejorar la comunicación entre equipos, la aplicación también contribuye a reducir errores humanos y a asegurar el cumplimiento de plazos críticos.

Entre sus características, OnTrack permite la asignación automática de tareas según su prioridad, el seguimiento del tiempo dedicado a cada actividad y la generación de alertas en caso de retrasos o problemas. Además, integra tecnología basada en la ubicación para verificar de manera instantánea la posición de los empleados, un aspecto fundamental en operaciones donde la puntualidad y precisión logística son esenciales.

Desde el punto de vista organizacional, OnTrack promueve la transparencia y fomenta una cultura de responsabilidad, ya que cada miembro del equipo puede visualizar sus objetivos y medir su rendimiento en relación con las metas establecidas. Asimismo, la aplicación resulta clave para la optimización de procesos, permitiendo a los administradores identificar cuellos de botella, implementar mejoras y asignar recursos de manera más eficiente.

OnTrack facilita la gestión de tareas y la productividad al ofrecer informes que analizan el rendimiento de los empleados y del equipo. Los usuarios pueden acceder al módulo de reportes de la plataforma para generar estos informes. Desde esta sección, es posible aplicar filtros según el equipo o empleado, el tipo de tarea, el estado (completado o en progreso) y el período de tiempo que se desee analizar.

Una vez configurados los filtros, OnTrack crea informes visuales que incluyen gráficos y estadísticas clave, como el tiempo diario promedio dedicado a las tareas, el porcentaje de finalización de los objetivos y las áreas que requieren mejora. Estos informes se pueden descargar en formatos como Excel o PDF, lo que facilita su presentación o un análisis más exhaustivo. Además, OnTrack ofrece la opción de programar informes automatizados y se integra con otras herramientas de gestión, convirtiéndose así en una solución eficaz para el monitoreo del rendimiento en tiempo real.

### **2.3. Depuración y/o limpieza de registros**

Una vez obtenidos los registros de ambas plataformas, se procedió a la depuración y limpieza de los datos, un proceso esencial para garantizar la calidad y confiabilidad de los análisis subsecuentes. Utilizando herramientas de software estadístico como RStudio, se implementaron técnicas específicas para identificar y eliminar registros que presentaran inconsistencias.

Antes de poner en marcha el análisis, es esencial llevar a cabo una revisión exhaustiva de los datos para evaluar las características de la información disponible mediante la exploración inicial se usan funciones de visualización básicas en RStudio, como **head()**, **summary()** o **str()**, para obtener una comprensión clara de la estructura, los valores y los tipos de datos presentes en el conjunto de registros.

Examinar los campos que contienen valores vacíos, aquellos con formatos inconsistentes (como fechas o nombres) y buscar elementos duplicados, las filas completamente vacías no contribuyen al análisis. Para eliminarlas, puedes utilizar la siguiente sentencia en RStudio:

```
data_clean <- data[complete.cases(data), ]
```

La duplicidad de registros puede generar errores significativos en los resultados del análisis. Es crucial identificar y eliminar duplicados, esto se puede lograr a través de la función `duplicated()` para encontrar registros repetidos. Una vez identificados, los duplicados pueden eliminarse conservando solo el primer registro mediante la sentencia en RStudio:

```
data_clean <- data[!duplicated(data), ]
```

La falta de información en algunas columnas puede reducir la calidad del análisis. Enfrentar esta dificultad, se pueden aplicar diferentes técnicas según la naturaleza de los datos tomando como ejemplo la eliminación de registros con valores nulos a través de la sentencia en RStudio:

```
data_clean <- na.omit(data)
```

También se puede realizar una imputación de valores faltantes mediante técnicas que se basan en la media, mediana o un valor constante.

Una vez que se han completado los pasos previos, se lleva a cabo una última verificación para asegurar que los datos sean consistentes y adecuados para su análisis. Al finalizar este proceso de depuración, los datos se cargan en una base de datos histórica, utilizando formatos que faciliten consultas eficientes y su reutilización en el futuro.

#### **2.4. Análisis exploratorio univariante**

Se realizó un análisis exploratorio inicial que tuvo como objetivo identificar las variables más relevantes en lo que respecta a la seguridad física y vial de los conductores y su entorno. Para lograr esto, se aplicaron diversas técnicas estadísticas que permitieron priorizar las variables con mayor impacto, facilitando un análisis más preciso. Mediante el uso de gráficos adecuados, se buscó simplificar la comprensión de la naturaleza de estas variables, su comportamiento a través del tiempo y su relación con los incidentes registrados. Con este enfoque, se procedió al procesamiento de dichas variables, utilizando gráficos de barras para ilustrar la frecuencia de los incumplimientos tanto en el colectivo de abastecimiento como en el de distribución.

Este enfoque permitió evidenciar el comportamiento individual de los conductores y, al mismo tiempo, realizar una comparación directa entre ambos colectivos. Además, este análisis contribuyó a ajustar los indicadores clave asociados a variables críticas como las velocidades excesivas y las paradas en lugares no autorizados, las cuales son monitoreadas mediante registros automatizados en la plataforma de seguimiento y monitoreo Tracklink.

Adicionalmente, se realizó un seguimiento exhaustivo para ambos colectivos (abastecimiento y distribución), enfocándose en el conteo semanal de cada incumplimiento detectado y registrado en la plataforma Tracklink. Este seguimiento proporcionó una visión clara de la evolución temporal de los diferentes incumplimientos, permitiendo al lector identificar patrones significativos y subrayar la importancia de un monitoreo continuo. A través de esta metodología, se pudo contrastar el comportamiento de los conductores durante el período de estudio, destacando las diferencias y similitudes entre los colectivos y priorizando las áreas que requieren intervención inmediata. De esta forma, se evidenció la necesidad de reforzar ciertas prácticas para garantizar la seguridad y el cumplimiento normativo en las operaciones.

Por otro lado, se incluyeron gráficos de dispersión para identificar posibles correlaciones entre diversas variables como somnolencia, desviaciones provocadas por distracciones y excesos de velocidad. Este análisis permitió inferir que el exceso de velocidad representa una de las principales causas de incidentes viales, validando resultados obtenidos en análisis previos. En línea con este enfoque, se incorporaron factores de riesgo adicionales como el recuento de pruebas de alcohol realizadas mediante alcohol test y la evaluación de riesgos neurocognitivos a través de Sobereye, un sistema que mide el reflejo pupilar para detectar alteraciones potenciales en el estado físico y mental del conductor. Este conjunto de análisis permite establecer una relación directa entre los comportamientos inseguros y los factores de riesgo asociados a los incidentes, destacando su importancia en la gestión operativa de la flota.

Finalmente, y como se detalla en la sección siguiente, se elaboró una tabla resumen que integra de forma estructurada todos los factores analizados. Esta tabla constituye una herramienta clave para la toma de decisiones, ya que permite visualizar de manera concisa y clara los elementos críticos que deben ser evaluados antes del inicio de las labores diarias por parte de los encargados del transporte de materia prima de G.L.P.

Su diseño responde a la necesidad de garantizar que las condiciones físicas y operativas cumplan con la normativa vigente, minimizando riesgos y mejorando la eficiencia del proceso. Este resumen busca ofrecer una base sólida de información para el análisis posterior de cada colectivo, asegurando que los resultados obtenidos contribuyan directamente al desarrollo de medidas preventivas y correctivas en las operaciones diarias.

Este análisis integrado no solo permitió evaluar y priorizar las variables de impacto, sino que también destacó la importancia de utilizar herramientas gráficas y técnicas estadísticas avanzadas. Esto facilita no solo el entendimiento de los datos, sino también su utilidad práctica en la mejora continua de los procesos de transporte y seguridad vial.

## **2.5.Creación de base de datos adicionales**

A través de un análisis descriptivo y univariante, se logró identificar y seleccionar las variables más pertinentes para gestionar de manera efectiva los factores relacionados con la conducta en los distintos grupos. Esta metodología analítica nos permite priorizar las variables que tienen un impacto significativo en la gestión operativa, la prevención de incidentes y el cumplimiento normativo. Reconocer estas variables es un paso fundamental para desarrollar una estrategia de monitoreo y control que garantice intervenciones oportunas en las áreas más críticas.

El análisis se enfocó en establecer un sistema de registro resumido que posibilite un seguimiento riguroso de los totales mensuales de estas variables. Este registro está diseñado para obtener información en una base de datos estructurada, lo que facilita su análisis y la identificación de

patrones, tendencias y anomalías a lo largo del tiempo. Cada columna de esta base de datos corresponde a una característica o variable previamente seleccionada mediante el correspondiente análisis, mientras que las filas representan los meses en los que se agruparon los datos. Este diseño proporciona una visualización clara y sistemática de la información recopilada, permitiendo su uso en análisis descriptivos y modelos predictivos.

Los registros mensuales de las variables seleccionadas abarcan diversos aspectos relacionados con las operaciones y el rendimiento del grupo. Entre las variables analizadas se encuentran factores como el número de infracciones por exceso de velocidad, paradas no autorizadas, desviaciones de ruta y otras actividades clave identificadas durante las operaciones diarias. Este enfoque brinda una comprensión integral del comportamiento del conductor y de las condiciones generales en las que se desarrollan las operaciones de transporte, aspecto esencial para implementar de manera efectiva acciones correctivas y preventivas.

Además, el diseño de la base de datos no solo permite un enfoque descriptivo, sino que también facilita análisis más avanzados, como la creación de gráficos temporales y comparativos para evaluar la evolución de las variables a lo largo del tiempo. Por ejemplo, se pueden elaborar gráficos de líneas que permitan observar irregularidades mensuales, identificando períodos de frecuencia que pueden relacionarse con factores específicos como cambios estacionales, incrementos en la demanda o condiciones operativas particulares. Estos gráficos no solo hacen más accesible la interpretación de los datos, sino que también ayudan a identificar relaciones entre las variables y las posibles causas de las infracciones.

El registro sistemático y la organización de los datos en esta base de datos facilitan el análisis cruzado de variables, brindando información valiosa para entender las interacciones entre los distintos factores de riesgo. Por ejemplo, al comparar el número de infracciones por exceso de velocidad con los registros de desviaciones de ruta, se puede identificar si hay una relación directa entre ambas variables y si las desviaciones incrementan la probabilidad de que se produzcan excesos

de velocidad. Este tipo de análisis es fundamental para priorizar acciones específicas que mejoren el desempeño del grupo.

Asimismo, los datos mensuales permiten realizar comparaciones entre diferentes períodos del año. Al examinar registros agregados, se puede determinar si las infracciones tienden a aumentar durante meses concretos o en ciertos picos estacionales. Esta información es clave para desarrollar estrategias dirigidas a abordar causas específicas de falta de adherencia, optimizando así los recursos disponibles y maximizando la efectividad de las intervenciones.

Además, la creación de esta base de datos posibilita la generación de informes detallados que son extremadamente útiles para la toma de decisiones estratégicas. Estos informes pueden incluir análisis gráficos y tabulares que ofrecen una visión clara y comprensible de los datos para los diferentes niveles de gestión. Esta información también puede utilizarse para capacitar y concienciar a los directivos, ya que permite ilustrar de manera objetiva las consecuencias de ciertas acciones y fomentar prácticas seguras y responsables.

En este contexto, el registro mensual de variables relevantes tiene como finalidad no solo explorar la incidencia de infracciones, sino también fomentar una cultura de seguridad vial dentro del grupo. Al ofrecer datos claros y cuantificables, el sistema permite evaluar la efectividad de las medidas adoptadas, ajustar las estrategias cuando sea necesario y mantener una postura proactiva ante la gestión de riesgos. Este enfoque estructurado y fundamentado en datos representa un avance significativo en la gestión de las operaciones de autobuses, ya que proporciona herramientas efectivas para asegurar un control riguroso y promover un entorno laboral más seguro y sostenible.

La base de datos no solo agrupa información en un formato accesible y fácil de analizar, sino que también establece las bases para un proceso de mejora continua que contribuye a reducir las infracciones y aumentar la seguridad en las operaciones cotidianas. Estos esfuerzos reflejan el compromiso de la organización con la excelencia operativa y la implementación de buenas prácticas

en todos los niveles.

## **2.6. Implementación de árboles de decisión**

Se desarrollarán árboles de decisión con el propósito de analizar cómo variables independientes, como la deriva, la somnolencia, los resultados positivos en las pruebas de alcoholemia y el alto riesgo identificado por Sobereye, contribuyen a las infracciones por exceso de velocidad registradas. Este enfoque tiene como objetivo identificar y visualizar de manera clara la relación entre estas variables predictoras y la respuesta, centrada en el exceso de velocidad, que se reconoce como uno de los principales factores causantes de accidentes de tráfico.

En un árbol de decisión, cada nodo representa un estado específico vinculado a una variable independiente. A través de estas relaciones, los datos se dividen en subgrupos, clasificándolos según los valores de las variables relevantes. Por ejemplo, un nodo podría reflejar si el conductor presenta signos de somnolencia, separando así los datos en dos grupos: uno para conductores somnolientos y otro para aquellos que no lo están. Este proceso de partición se repite en cada nivel del árbol, generando un modelo jerárquico que descompone los datos en categorías cada vez más específicas. Finalmente, los nodos terminales, conocidos como hojas, contienen las predicciones o resultados del modelo, tales como la probabilidad o la velocidad promedio en un escenario determinado.

Para implementar este modelo, se hará uso de una base de datos preconstruida, la cual se basa en registros consolidados mensuales. Esta base de datos incluye información fundamental sobre las variables predictivas y el historial de infracciones de velocidad, facilitando así la creación de modelos sólidos que se adapten a las particularidades del entorno operativo. Una de las principales ventajas de los árboles de decisión es su habilidad para procesar datos complejos de manera intuitiva, así como representar gráficamente la interacción entre variables de forma clara y comprensible. Esto no solo simplifica el análisis, sino que también mejora la comunicación de los resultados a los

tomadores de decisiones.

Los modelos que utilizan árboles de decisión permiten identificar patrones y tendencias que pueden pasar desapercibidos en un análisis tradicional. Por ejemplo, podrían evidenciar que una desviación de ruta, combinada con un alto riesgo de Sobereye, incrementa considerablemente la probabilidad de incurrir en exceso de velocidad. Esta información resulta crucial para desarrollar estrategias de intervención más efectivas, ya que facilita la priorización de acciones basadas en las condiciones más relevantes. Asimismo, este enfoque no solo identifica las variables más significativas, sino que también cuantifica su influencia relativa sobre la variable de respuesta. De este modo, un modelo podría, por ejemplo, indicar que la somnolencia tiene un impacto mayor en la frecuencia del exceso de velocidad que un resultado positivo en una prueba de alcoholemia, lo que llevaría a centrar los esfuerzos de prevención en detectar y reducir la fatiga del conductor. Al mismo tiempo, los registros ofrecen una estimación clara de la tasa promedio de infracciones en cada caso, asistiendo a los responsables en la toma de decisiones informadas.

Una vez que se ha creado un modelo, es posible llevar a cabo análisis adicionales, como la validación cruzada, que permite evaluar su precisión, así como realizar ajustes para optimizar su desempeño. Esto asegura que las predicciones sean confiables y efectivas en el contexto operativo. Además, los árboles de decisión pueden servir de base para entrenar modelos más avanzados, o bien, para generar informes y visualizaciones que contribuyan a mejorar la seguridad vial y a optimizar la gestión de riesgos.

## 2.7. Implementación del Sistema de Indicadores

Se procedió a tomar en consideración indicadores para las variables más relevantes resultantes del análisis anterior junto con la cantidad de accidentes en planta los cuales son clasificados mediante la gravedad del incidente las siglas IFV en una escala nominal donde el factor 1 es el menos grave, 2 corresponde a una gravedad intermedia y 3 pertenece a fatalidades con pérdidas irre recuperables.

Se tomó la  $k = \frac{1}{\text{cantidad de Kilómetros recorridos}}$  (2.1), por cada colectivo de transportistas (Abastecimiento y Distribución) como un factor de normalización para los indicadores de seguridad vial.

Para los indicadores de seguridad física se tomó como factor de normalización  $m = \frac{1}{\text{la cantidad de incidentes en plantas sin distinguir de la gravedad}}$  (2.2), estos indicadores se colocarán en un panel de control o gestor de indicadores de seguridad (G.I.S) el cual tendrá como periodicidad mensual, siendo un resumen del comportamiento del personal que dará a conocer una ratio del cumplimiento de las normas de seguridad vial y física.

Para llevar un mejor control también se incluyó un indicador proveniente de la plataforma de geolocalización que dará una visión general de cuantas alertas se encuentran atendidas, esto se logró realizando la razón entre las aletas atendidas/Total de alertas registradas.

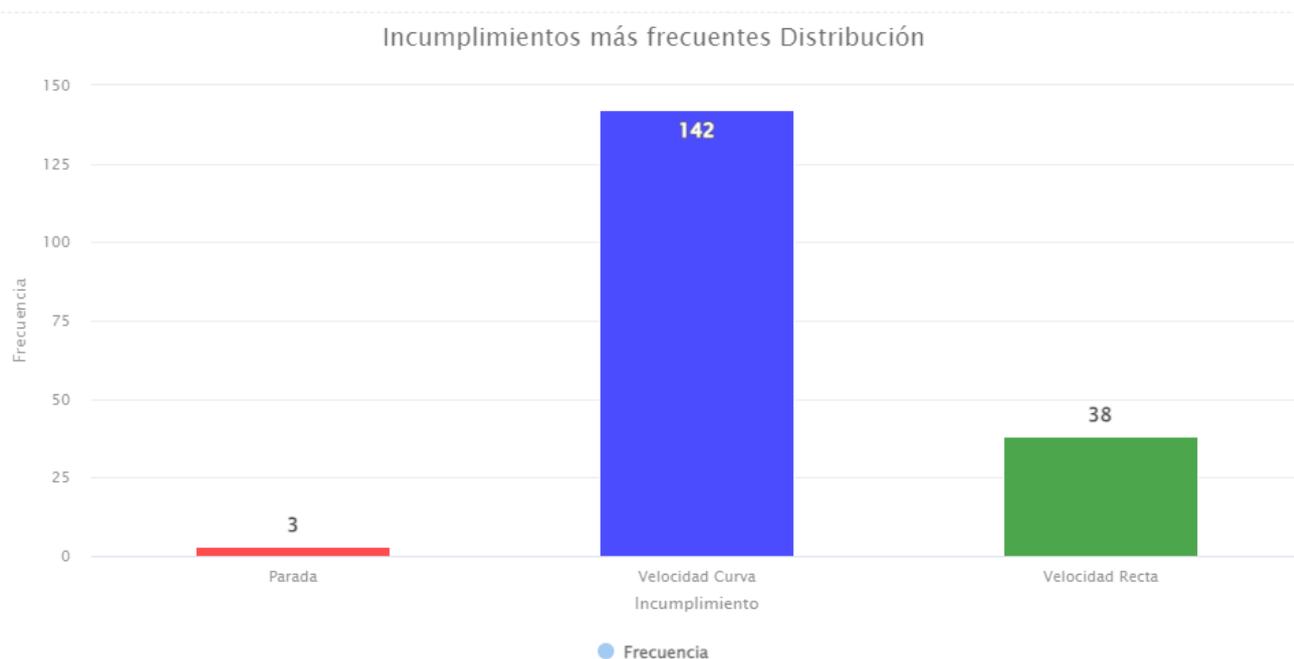
## Capítulo 3

### 3. Resultados y análisis

Para los resultados, debemos conocer que existen dos grupos de viajes: de Distribución que es cuando los choferes tienen recorridos cortos, y los de Abastecimiento son de los choferes que tienen recorridos más largos.

**Figura 3.1**

**Frecuencia de incumplimientos del periodo enero a diciembre colectivo de distribución.**

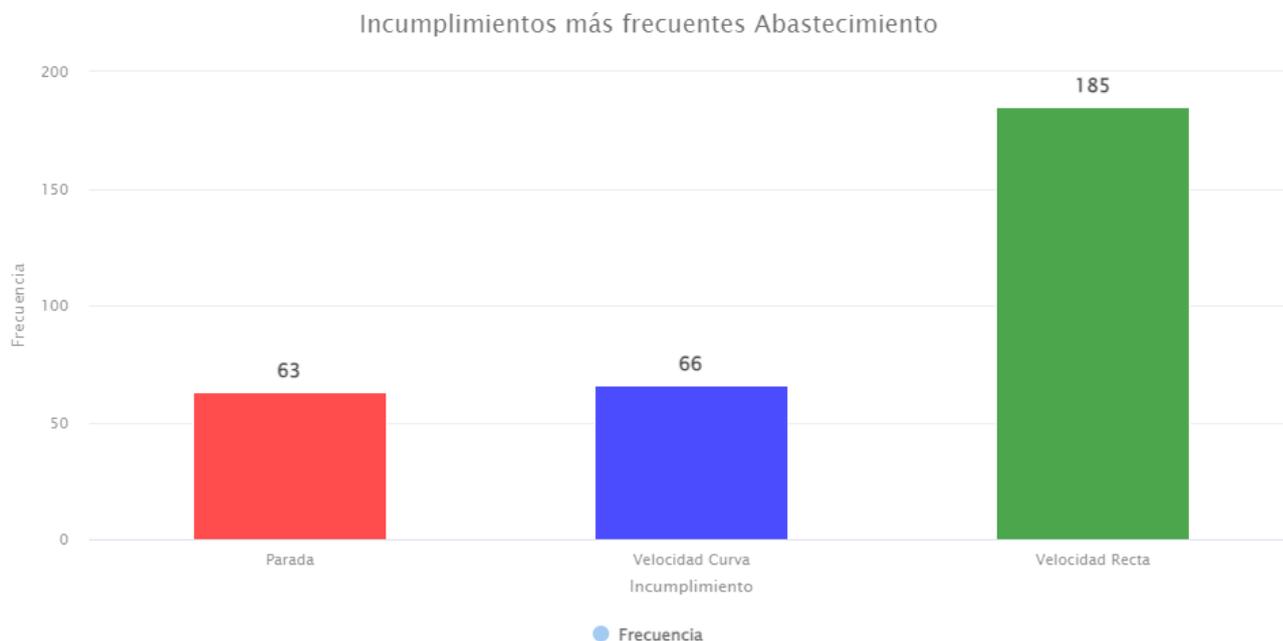


**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink.

En el grupo de Distribución usando la aplicación de geolocalización Tracklink, se encontró que los incumplimientos más frecuentes de los choferes de las unidades (Figura 3.1) son en velocidad curva (142), esto significa que los choferes toman una curva con un exceso de velocidad, seguido de velocidad recta (38), que indica que los choferes exceden la velocidad permitida en una dirección recta, y sólo 3 veces los choferes se estacionan en lugares categorizados como inseguros.

**Figura 3.2**

**Frecuencia de incumplimientos del periodo enero a diciembre colectivo de abastecimiento.**

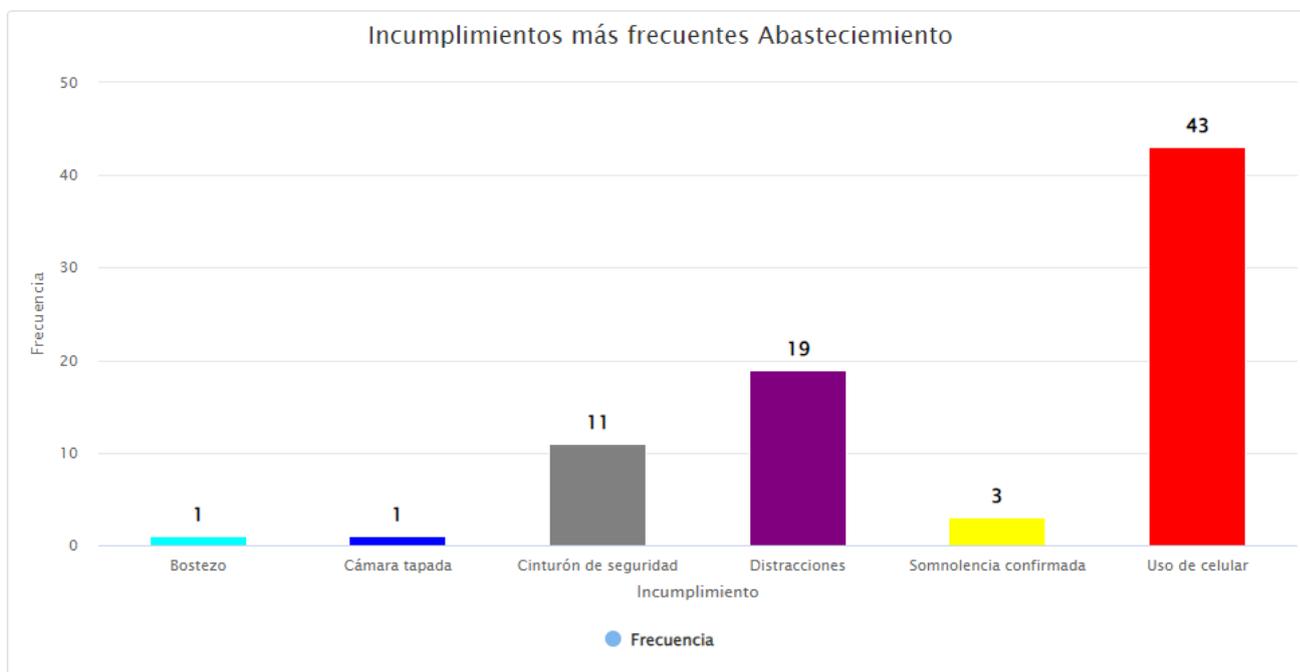


**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink.

En el grupo de Abastecimiento usando la aplicación de geolocalización Tracklink, se logró ver que los incumplimientos más frecuentes de los choferes de las unidades (Figura 3.2) son en velocidad recta (185), esto significa que los choferes toman una recta con un exceso de velocidad, seguido de velocidad curva (66), que indica que los choferes toman una ruta curva con un exceso de velocidad, y 63 veces los choferes se estacionan en lugares categorizados como inseguros. Estos resultados fueron consistentes debido a que como los choferes realizan rutas más largas, tienden a exceder la velocidad en línea recta, para llegar más rápido, además al ser trayectos de mucho tiempo, estos realizan varias paradas para descansar, para estos descansos, existen las paradas seguras, las cuáles son lugares donde la unidad puede estar de manera segura para el chofer y el producto, sin embargo, no lo hacen.

**Figura 3.3**

**Frecuencia de incumplimientos del periodo enero a diciembre colectivo de abastecimiento ontrack.**

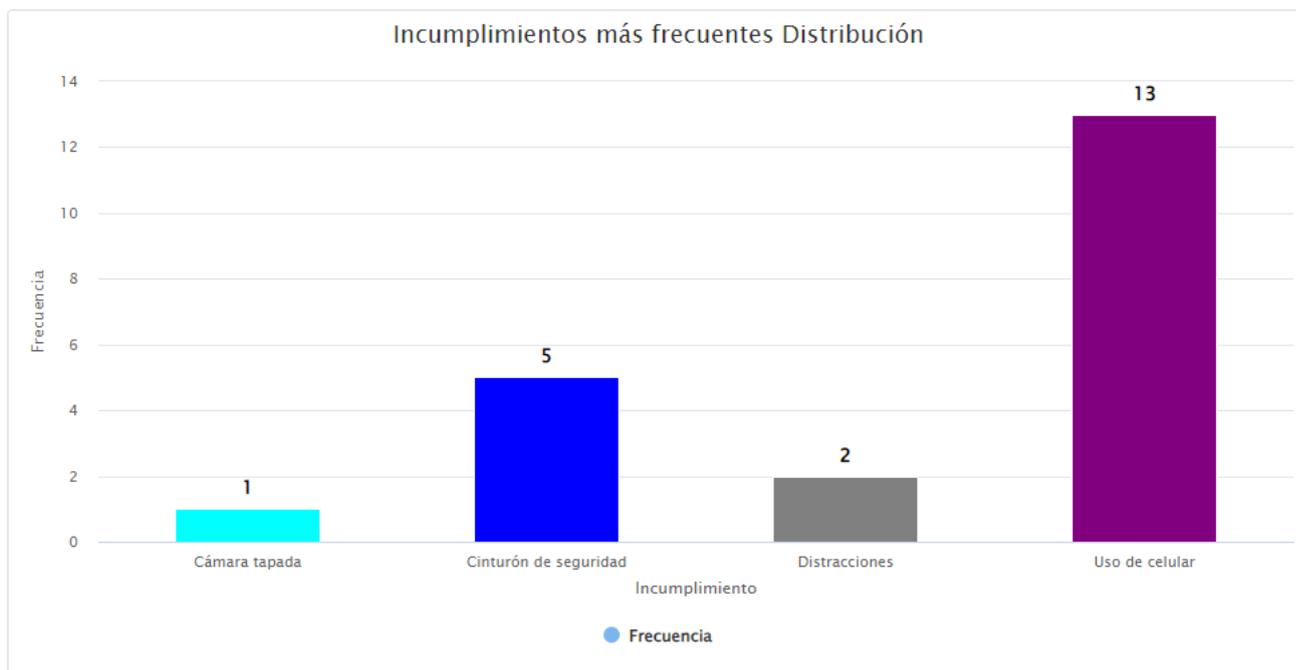


**Nota.** Elaborado en R utilizando datos de registros de plataforma ontrack.

En el grupo de Abastecimiento usando las cámaras OnTrack, se logró ver que los incumplimientos que los choferes más frecuentan (Figura 3.3) son más variados y detallados, teniendo en primer lugar al uso de celular mientras conducen (43), en segundo lugar, las distracciones (19), que es cuando el conductor no mira la ruta y mira hacia otro lado que no debe durante el trayecto, y en tercer lugar es el no uso del cinturón de seguridad (11), ya sea por parte del chofer o el/los acompañantes. Las sanciones menos frecuentes fueron que el chofer o su acompañante bostecen (1), que tengan la cámara tapada (1) y la somnolencia confirmada (3) que es cuando el chofer se va durmiendo en el camino o va “cabeceando”.

**Figura 3.4**

**Frecuencia de incumplimientos del periodo enero a diciembre colectivo de distribución ontrack.**

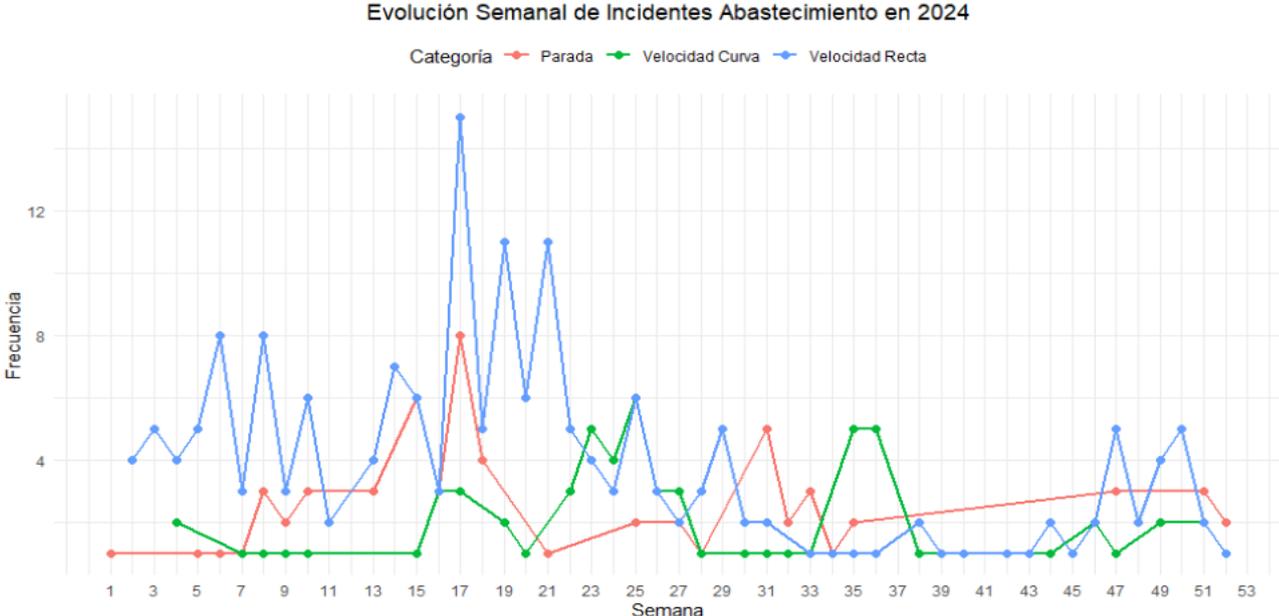


**Nota.** Elaborado en R utilizando datos de registros de plataforma ontrack.

En el grupo de Distribución usando las cámaras OnTrack, se pudo ver que los incumplimientos que los choferes más frecuentan (Figura 3.4) son en primer lugar, así como en los conductores de Abastecimiento, el uso de celular mientras conduce (13), en segundo lugar, el no uso cinturón de seguridad (19) ya sea por el chofer o el/los acompañantes, los otros incumplimientos son las distracciones (2) y que van con la cámara tapada (1). Se notó también que en este grupo no se producen los incumplimientos de bostezo y somnolencia, ya que estos conductores tienen recorridos más cortos, en comparación al otro grupo.

**Figura 3.5**

**Evolución Semanal de incumplimientos del grupo de Abastecimiento periodo enero a diciembre.**



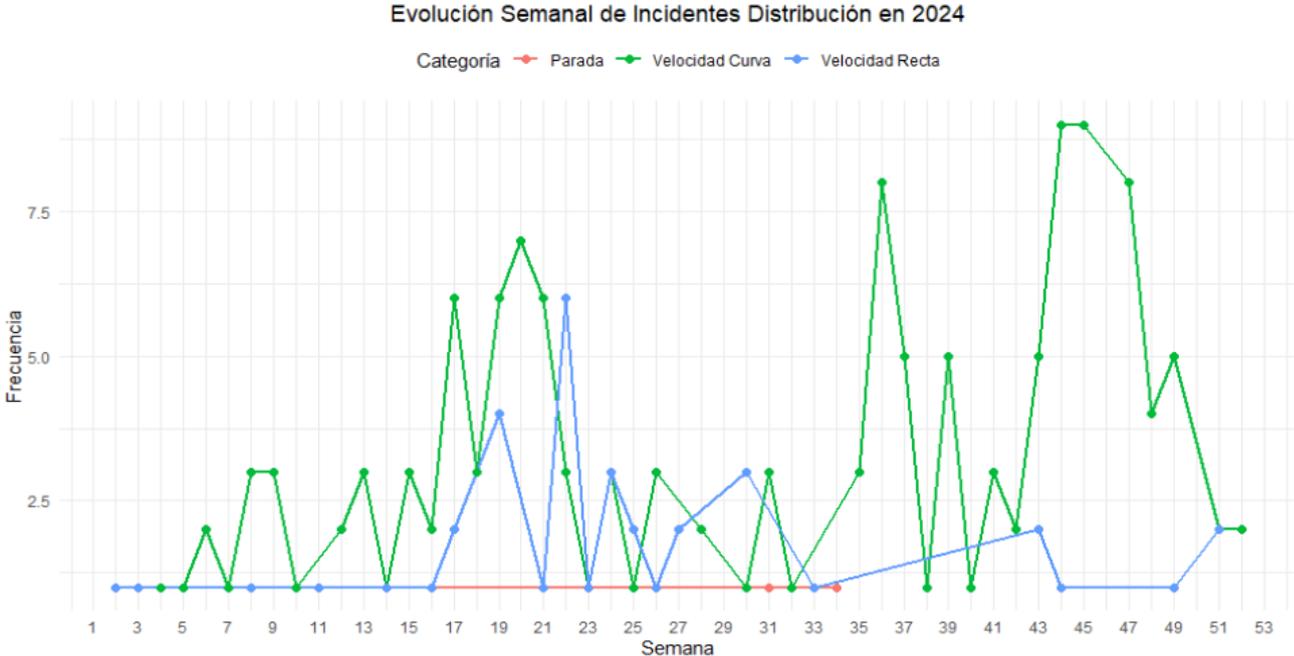
**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink.

Para el grupo de Abastecimiento usando la aplicación Tracklink, con respecto a las tendencias semanales de los incidentes (Figura 3.5), se encontró que las sanciones por exceso de velocidad en línea recta (línea azul) son más frecuentes en todo el año 2024, también se destacó un pico significativo en la semana 17 (más de 12 incidentes), mientras que las sanciones por una parada en un lugar no seguro (línea roja), tiene un crecimiento gradual hasta la semana 17, ya de ahí en adelante se vuelven menos frecuentes hasta la semana 31. Finalmente, con respecto a las sanciones por exceso de velocidad en curvas (línea verde), son menos frecuentes con picos aislados, en la semana 35 y 36.

De manera general, los incumplimientos más frecuentes de los choferes semanalmente, durante la semana 17 hasta la semana 21, correspondiente a parte del mes de abril y parte del mes de mayo, es cuando los choferes han obtenido más sanciones por exceso de velocidad en una trayectoria recta y han realizado paradas en lugares no seguros. Mientras que se encontró que las sanciones de los choferes por exceso de velocidad en una trayectoria curva son más frecuentes desde la semana 21 hasta la semana 27 y desde la semana 35 hasta la semana 36.

**Figura 3.6**

**Evolución Semanal de los incumplimientos del grupo de Distribución periodo enero a diciembre.**



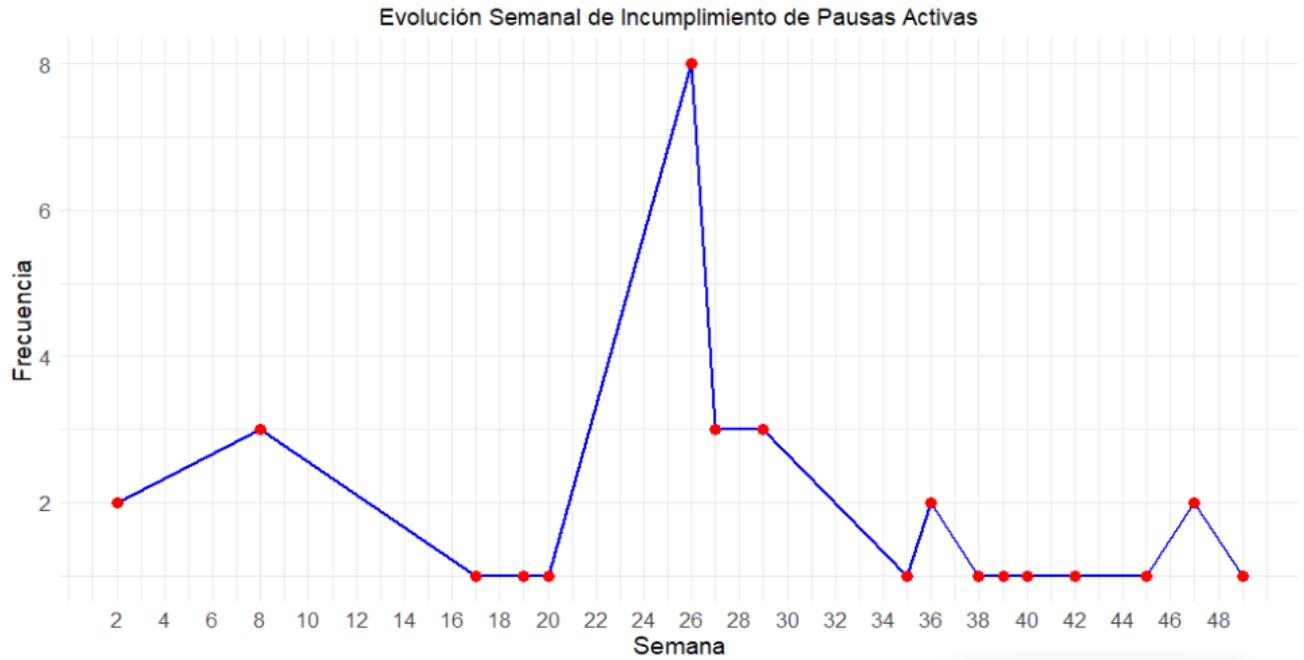
**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink.

Para el grupo de Distribución usando la aplicación Tracklink, con respecto a las tendencias semanales de incidentes (Figura 3.6), se halló que las sanciones por exceso de velocidad en línea curva (línea verde) son más frecuentes y con una tendencia irregular pero predominante a lo largo del año 2024, también se destacaron varios picos significativos en las semanas 36, 44, 45 y 47 con más de 7 incidentes en cada semana. Los incumplimientos por ir a exceso de velocidad en una trayectoria recta (línea azul) tienen menor frecuencia que las sanciones en trayectoria curva. Finalmente, las sanciones por realizar paradas en lugares no seguros (línea roja), tuvieron la menor frecuencia y una tendencia constante, prácticamente sin cambios durante todo el año 2024.

De manera general, desde la semana 17 hasta la semana 31, se encontró la mayor concentración de sanciones tanto por exceso de velocidad en trayectoria recta y trayectoria curva, semanas que corresponden a finales del mes de abril hasta los primeros 4 días del mes de agosto.

**Figura 3.7**

**Evolución Semanal de los incumplimientos de pausas activas periodo enero a diciembre.**



**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink.

A través de LA Figura 3.7 se pudo evidenciar una tendencia decreciente en la cantidad de incumplimientos de los descansos conocidos como pausas activas que permiten al conductor seguir con su ruta sin inconvenientes que causen distracciones este logro es consecuencia de ir implementando el tablero de control de gestión de indicadores de seguridad (G.I.S) a partir de la semana 27 correspondiente al mes de Julio. Además, se evidenció un pico en la semana 26 con 8 incumplimientos de Pausas Activas

**Tabla 3.1****Resumen de las variables principales de alto riesgo para el colectivo de Abastecimiento.**

Meses	Excesos de Velocidad	Cumplimiento horas de manejo	Alcohol positivo	Alto riesgo Sobereye	Desviaciones detectadas	Somnolencias
Enero	15	4	1	18	51	39
Febrero	29	12	0	15	43	41
Marzo	14	2	0	15	77	22
Abril	42	4	0	12	67	41
Mayo	38	3	1	5	50	48
Junio	39	5	0	11	53	31
Julio	19	1	0	9	57	34
Agosto	12	1	0	5	56	15
Septiembre	11	1	0	7	52	6
Octubre	5	4	3	3	55	11
Noviembre	14	2	3	5	56	15
Diciembre	18	3	1	15	53	11

**Diccionario de variables**

Meses: hace referencia al mes de observación.

Excesos de Velocidad: hace referencia a la cantidad de excesos de velocidad durante el mes de observación.

Cumplimiento horas de manejo: hace referencia a la cantidad de incumplimientos de parte de los conductores que superan las 9 horas de conducción detectados durante el mes de observación.

Alcohol positivo: hace referencia a la cantidad de incumplimientos detectados de conductores con ingesta de alcohol previo al inicio de su recorrido durante el mes de observación.

Alto riesgo Sobereye: hace referencia a la cantidad de incumplimientos detectados de conductores con alteraciones cognitivas como cansancio visual o presencia de sustancias que alteren el sistema nervioso previo al inicio de su recorrido durante el mes de observación.

Desviaciones detectadas: incumplimientos detectados tales como cinturón de seguridad desabrochado, distracciones en la vía o dentro de la cabina de manejo tales como contar dinero o colocar objetos desviando la atención.

Somnolencias: la cantidad de somnolencias confirmadas a través de validación de videos de la cabina de conducción detectadas durante el mes de observación.

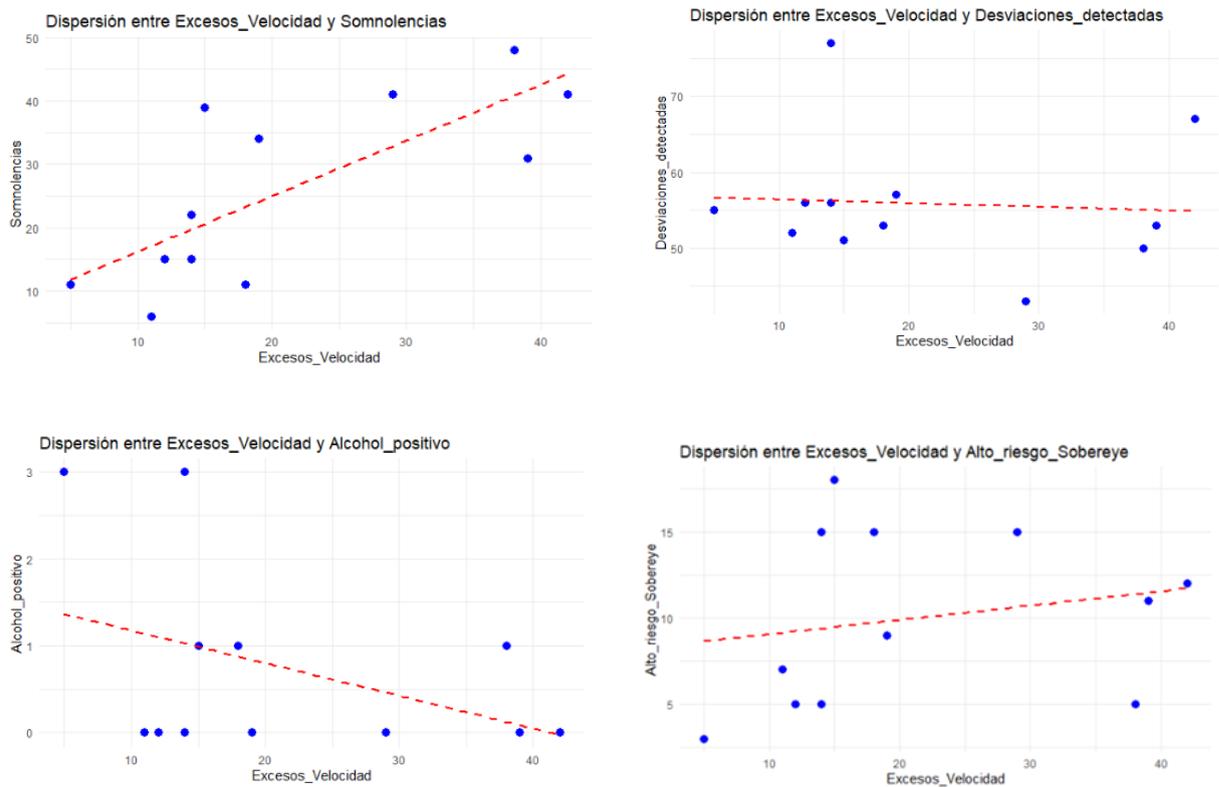
Esta tabla muestra una variación notable en las variables relacionadas con el comportamiento del conductor y los factores de riesgo. En abril, se registró el mayor número de casos de exceso de velocidad (42), mientras que en octubre se observó el menor (5). Por otro lado, el control del tiempo de conducción se mantuvo generalmente bajo, alcanzando su punto más alto en febrero (12), pero sin una correlación evidente con la disminución de infracciones.

Aunque las pruebas de alcohol positivas fueron poco frecuentes, se destacaron algunos casos en octubre y noviembre (3), coincidiendo con una reducción en los incidentes de exceso de velocidad. En cuanto a los altos riesgos detectados por Sobereye, se evidenció una disminución gradual, comenzando con 18 casos en enero y reduciéndose a 3 en octubre, si bien marzo y diciembre también mostraron altos niveles de violaciones con 15 casos cada uno.

Las anomalías observadas resultaron consistentes, ya que la mayoría de los meses superaron una tasa de 50. Abril destacó con un notable 67, coincidiendo además con el mayor número de infracciones por exceso de velocidad. La somnolencia presentó variaciones significativas, alcanzando su máximo en mayo (48 casos) y disminuyendo en septiembre (6 casos), lo que sugiere una posible relación con el exceso de velocidad en ciertos meses.

**Figura 3.8**

**Gráficos de dispersión para los principales pares de variables de la base de datos de Abastecimiento.**



**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink y ontrack.

Los gráficos de la Figura 3.10 permitieron ver la relación entre la variable "Excesos de Velocidad" y las cuatro otras 4 variables predictoras (Somnolencias, Desviaciones detectadas, Alcohol positivo y Alto riesgo Sobereye).

En el primer gráfico (superior izquierdo), se observó una relación positiva entre los excesos de velocidad y la somnolencia. Es decir que, a medida que aumentan los excesos de velocidad, se incrementa también la somnolencia, lo que implica que los conductores más propensos a exceder los límites de velocidad también tienden a tener mayores niveles de fatiga o falta de atención.

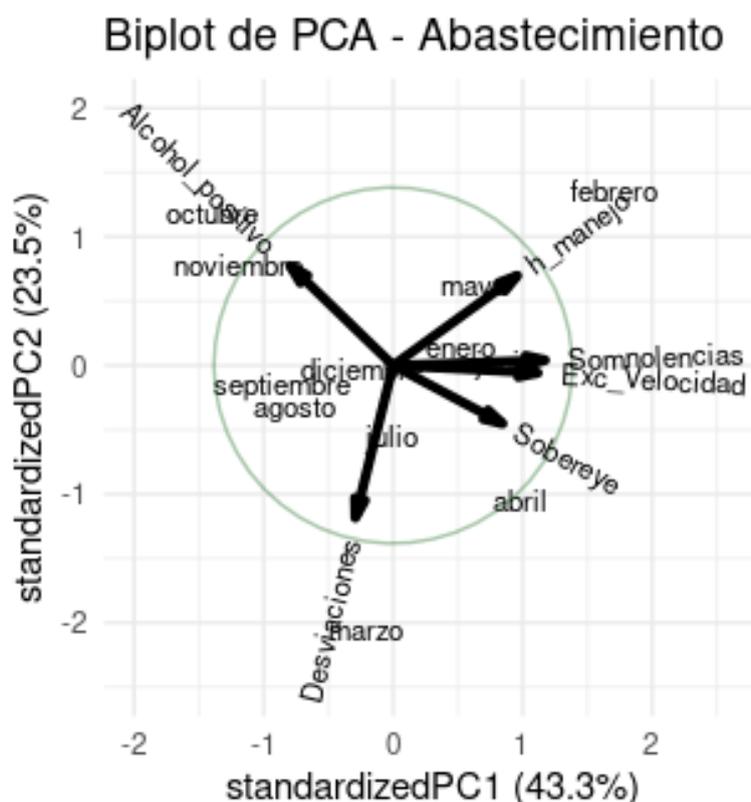
En el segundo gráfico (superior derecha) no se observó una relación entre los excesos de velocidad y las desviaciones detectadas. Esto sugiere que no existe una correlación significativa entre ambas variables, es decir, son independientes.

En el tercer gráfico (inferior izquierdo), se observó una tendencia negativa, lo que implica que los conductores con más excesos de velocidad tienden a presentar niveles positivos de alcohol en su organismo.

Por último, en el cuarto gráfico (inferior derecha), se encontró una tendencia es ligeramente positiva, lo que indica que un aumento en los excesos de velocidad puede estar asociado con un mayor riesgo en este tipo de maniobras. Esto refleja un comportamiento imprudente de los conductores al transitar a altas velocidades.

**Figura 3.9**

**Biplot de Análisis de Componentes Principales (Abastecimiento).**



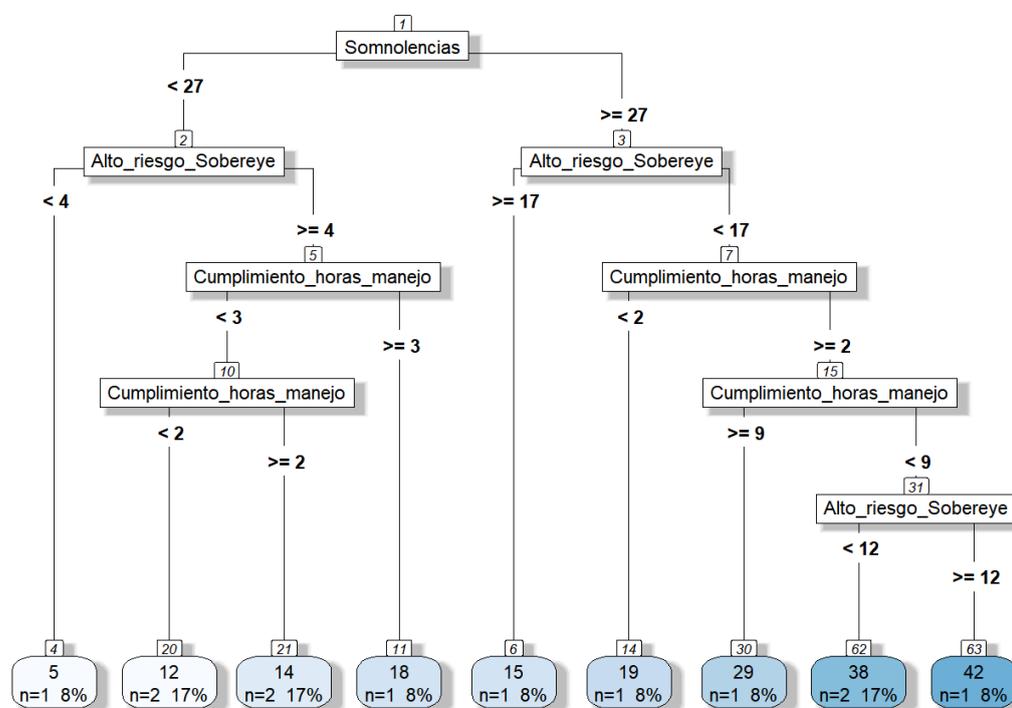
**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink y ontrack

En la Figura 3.9 se evidenció que el eje horizontal (Componente Principal 1) explica el 43.3% de la variabilidad en los datos, y el eje vertical (Componente Principal 2) el 23.5%. De manera general, ambas componentes explican el 66.8% de la variabilidad total, por lo que indica un buen resumen del conjunto de datos. Los meses están distribuidos en diferentes cuadrantes según sus

características. Es quiere decir que, en el mes de abril tiene mayor incidencia la variable Alto\_riesgo\_sobereye, en el mes de julio tienen mayor incidencia las desviaciones detectadas. Además, las somnolencias y los excesos de velocidad están correlacionadas positivamente y tienen mayor incidencia en los meses de enero y junio. Con respecto a los casos de alcohol positivo, se observó que tiene mayor incidencia en los meses de octubre y noviembre.

**Figura 3.10**

**Árbol de decisión con la predicción de la tasa promedio de excesos de velocidad (Abastecimiento).**



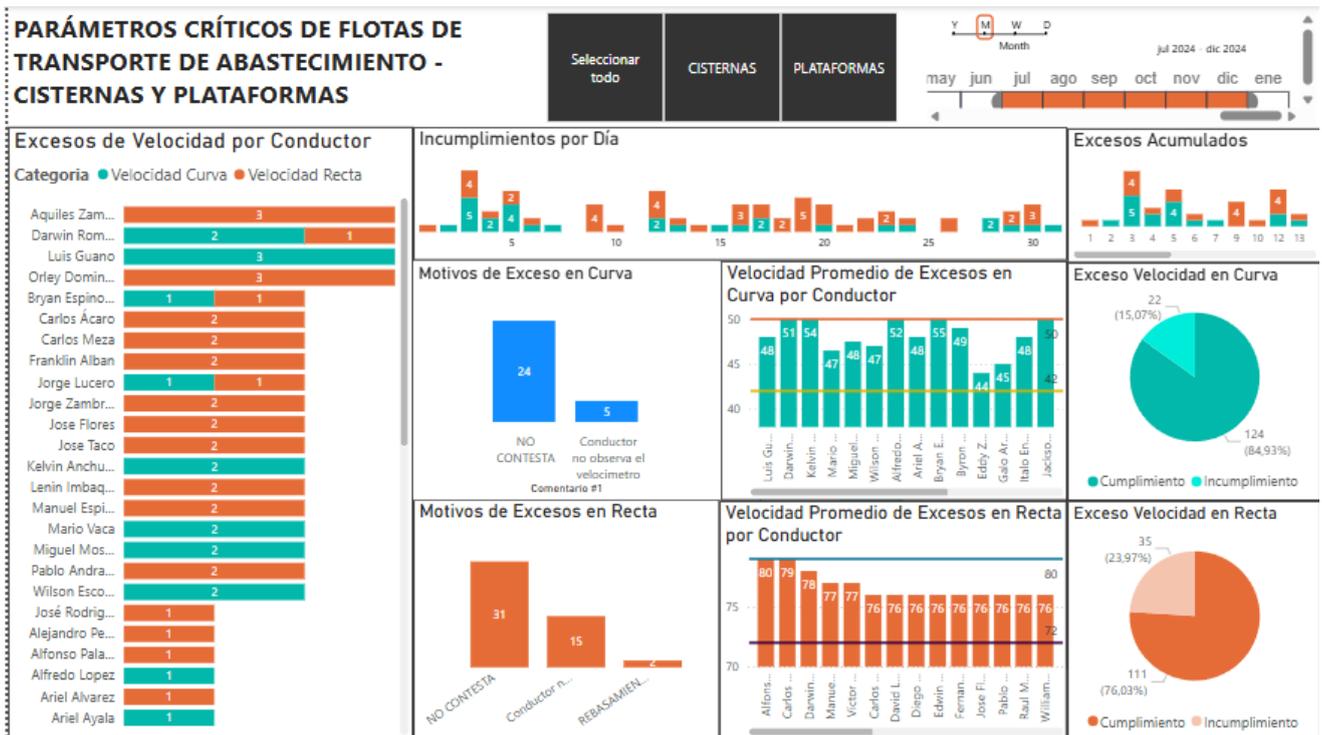
**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink y ontrack.

El árbol de decisiones de la Figura 3.8 muestra cómo las variables independientes (desviación detectada, somnolencia, prueba de alcohol positiva y alto riesgo de Sobereye) afectan para que se produzcan las infracciones por exceso de velocidad registradas en el colectivo de abastecimiento. Cada nodo representa una condición para una variable, dividiendo los datos en subgrupos según el valor de la variable. Los nodos finales (hojas) contienen la predicción de la tasa promedio de excesos de velocidad para este grupo de Abastecimiento.

El modelo utiliza métodos ANOVA para reducir la variabilidad dentro de los nodos y aumentar la discriminación de nodos. Los valores de la tabla muestran la velocidad media de los grupos resultantes, explicando así la influencia relativa de las variables sobre el fenómeno en estudio.

**Figura 3.11**

**Propuesta de Dashboard de control para los excesos de velocidad colectivo de Abastecimiento.**



**Nota.** Elaborado en Power BI utilizando datos de registros de plataforma tracklink.

La figura 3.11 muestra el prototipo de un dashboard diseñado para monitorear los incumplimientos de velocidad de conductores en la flota de transporte de abastecimiento, detallando excesos en curva y recta. Los gráficos permiten visualizar de forma clara el número total de excesos de velocidad cometidos por cada conductor, representados en barras para ambas categorías de velocidad, y distribuidos a lo largo del período de observación seleccionado.

El dashboard destaca aquellos conductores que presentan más incumplimientos, ofreciendo un desglose por día y categorizando los excesos en curva y recta. También se presentan gráficos circulares que muestran el porcentaje de cumplimiento e incumplimiento de los conductores, facilitando la comparación y evaluación de cada uno. Brindando información útil para tomar acciones correctivas. Esto permite una gestión eficiente y en tiempo real de la seguridad y el comportamiento de los conductores, ayudando a identificar puntos críticos para mejorar.

**Tabla 3.2**

**Resumen de las variables principales consideradas de alto riesgo para el colectivo de Distribución.**

Meses	Excesos de Velocidad	Cumplimiento horas de manejo	Alcohol positivo	Alto riesgo Sobereye	Desviaciones detectadas	Somnolencias
Enero	5	4	2	1	3	11
Febrero	10	0	0	3	6	6
Marzo	7	0	1	3	6	3
Abril	13	1	0	3	8	13
Mayo	27	0	0	0	6	12
Junio	8	0	0	0	7	4
Julio	12	0	2	6	6	1
Agosto	6	0	0	0	5	2
Septiembre	20	0	0	1	6	1
Octubre	20	0	0	0	5	4
Noviembre	24	0	0	0	6	0
Diciembre	12	0	1	1	5	4

## **Diccionario de variables**

Meses: hace referencia al mes de observación.

Excesos de Velocidad: hace referencia a la cantidad de excesos de velocidad durante el mes de observación.

Cumplimiento horas de manejo: hace referencia a la cantidad de incumplimientos de parte de los conductores que superan las 9 horas de conducción detectados durante el mes de observación.

Alcohol positivo: hace referencia a la cantidad de incumplimientos detectados de conductores con ingesta de alcohol previo al inicio de su recorrido durante el mes de observación.

Alto riesgo Sobereye: hace referencia a la cantidad de incumplimientos detectados de conductores con alteraciones cognitivas como cansancio visual o presencia de sustancias que alteren el sistema nervioso previo al inicio de su recorrido durante el mes de observación.

Desviaciones detectadas: incumplimientos detectados tales como cinturón de seguridad desabrochado, distracciones en la vía o dentro de la cabina de manejo tales como contar dinero o colocar objetos desviando la atención.

Somnolencias: la cantidad de somnolencias confirmadas a través de validación de videos de la cabina de conducción detectadas durante el mes de observación.

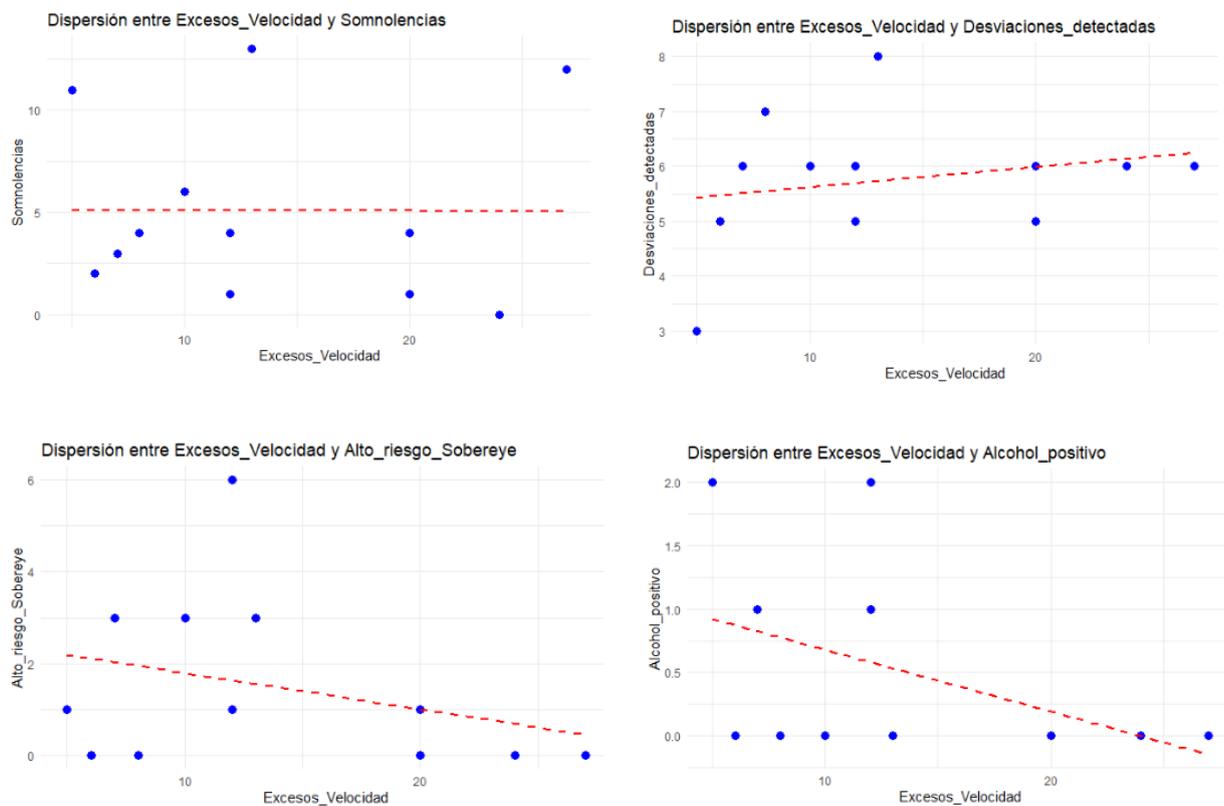
La tabla muestra los cambios mensuales en las infracciones por exceso de velocidad y otros factores de riesgo relacionados con el comportamiento al volante. Los picos de velocidad más altos se registraron en mayo (27), septiembre (20) y noviembre (24), mientras que los picos de velocidad más bajos se registraron en enero (5) y agosto (6). Con excepción de enero (4) y abril (1), el cumplimiento del tiempo de conducción fue relativamente bajo y, en general, no pareció estar asociado con una disminución de las infracciones. En cuanto a los casos positivos en las pruebas de alcoholemia, hubo pocos casos, principalmente en enero (2 casos) y julio (2 casos), y no hubo un vínculo evidente con el exceso de

velocidad. Por otro lado, Sobereye tuvo un nivel general de alto riesgo más bajo, alcanzando su punto máximo en julio (6), cuando se registraron 12 incidentes de exceso de velocidad.

Las desviaciones observadas en la mayoría de los meses suelen estar entre 5 y 8, sin cambios significativos que puedan explicar los cambios en el comportamiento delictivo. Por el contrario, la somnolencia mostró claras fluctuaciones con picos en enero (11) y abril (13), lo que puede estar relacionado con la conducción a alta velocidad en ciertos meses, aunque esta relación no fue homogénea.

**Figura 3.12**

**Gráficos de dispersión para los principales pares de variables de la base de datos de Distribución.**



**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink y ontrack.

Los gráficos presentados en la Figura 3.12 permitieron analizar la relación entre la variable "Excesos de Velocidad" y las otras variables predictoras acerca de las condiciones de los conductores, destacando las posibles correlaciones entre ellas.

En el primer gráfico (superior izquierdo), se observó una distribución dispersa de los puntos, con una tendencia casi constante. Esto indica que no existe una correlación entre la frecuencia de excesos de velocidad y los casos de somnolencia reportados.

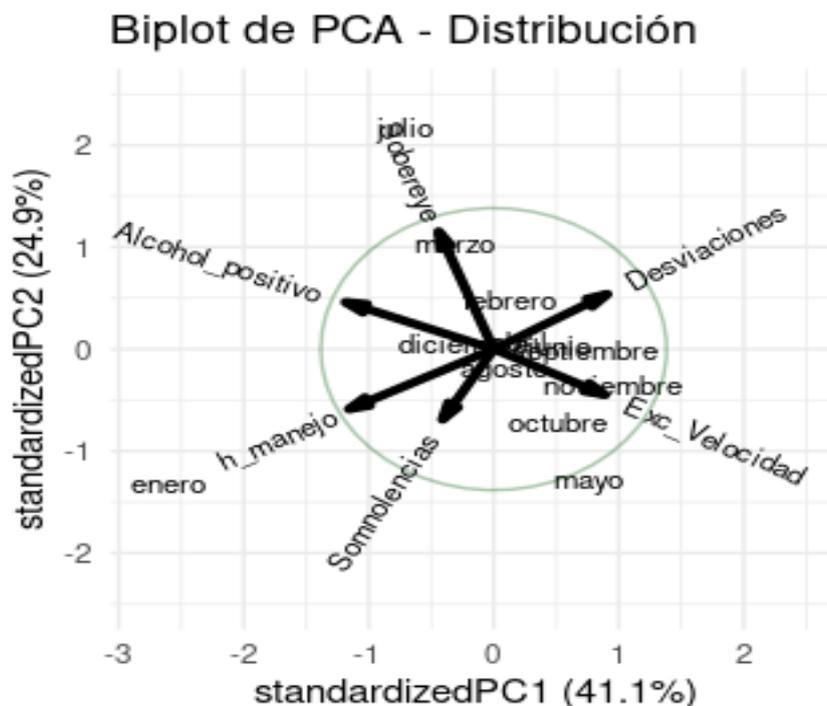
El segundo gráfico (superior derecha) indicó una tendencia con un ligero aumento, lo que sugiere que puede haber una leve correlación positiva entre ambas variables. Lo que implica que, a medida que los excesos de velocidad aumentan, también tienden a incrementarse el número de desviaciones detectadas.

En el tercer gráfico (inferior izquierdo) se encontró una tendencia negativa. Lo que indica que a medida que aumentan los excesos de velocidad, tienden a disminuir los casos reportados de alto riesgo.

Por último, el cuarto gráfico (inferior derecho) se evidenció una relación negativa entre los excesos de velocidad y los casos de alcohol positivo. Es decir que, a medida que los excesos de velocidad aumentan, tienden a disminuir los casos de alcohol positivo en los choferes.

**Figura 3.13**

**Biplot de Análisis de Componentes Principales (Distribución)**



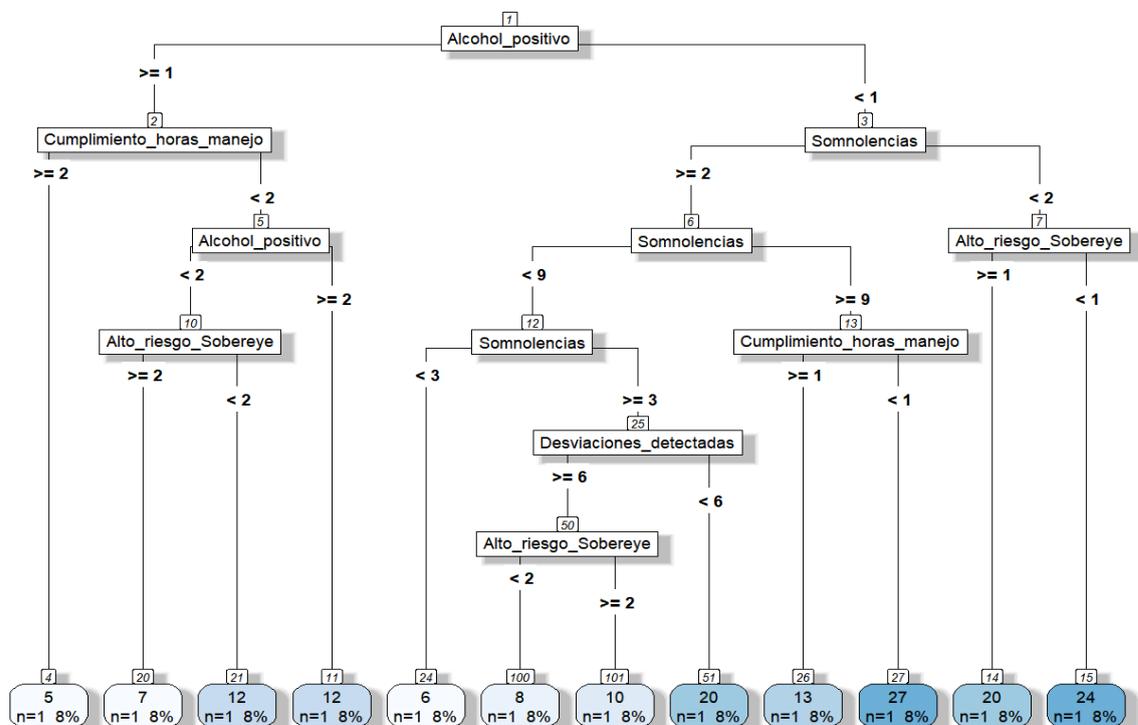
**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink y ontrack

En la Figura 3.13 se evidenció que el eje horizontal (Componente Principal 1) explica el 41.1% de la variabilidad en los datos, en cambio el eje vertical (Componente Principal 2) explica el 24.9%, y en conjunto las dos componentes explican el 66% de la variabilidad total, concluyendo que los patrones principales en los datos están bien representados. Se encontró también que los excesos de velocidad y las desviaciones detectadas tienen una fuerte correlación positiva, ya que van en la misma dirección, con respecto al cumplimiento de horas de manejo se pudo observar que está inversamente relacionada con los excesos de velocidad y las somnolencias.

Con respecto a los meses, estos se agrupan o dispersan según las similitudes en sus características, esto quiere decir que la variable Excesos\_Velocidad es una de la más importantes y de mayor incidencia en los meses de mayo, septiembre, octubre y noviembre, y la variable de Alto\_Riesgo\_Sobereye tiene mayor incidencia en el mes de marzo.

**Figura 3.14**

**Árbol de decisión con la predicción de la tasa promedio de excesos de velocidad (Distirbución).**

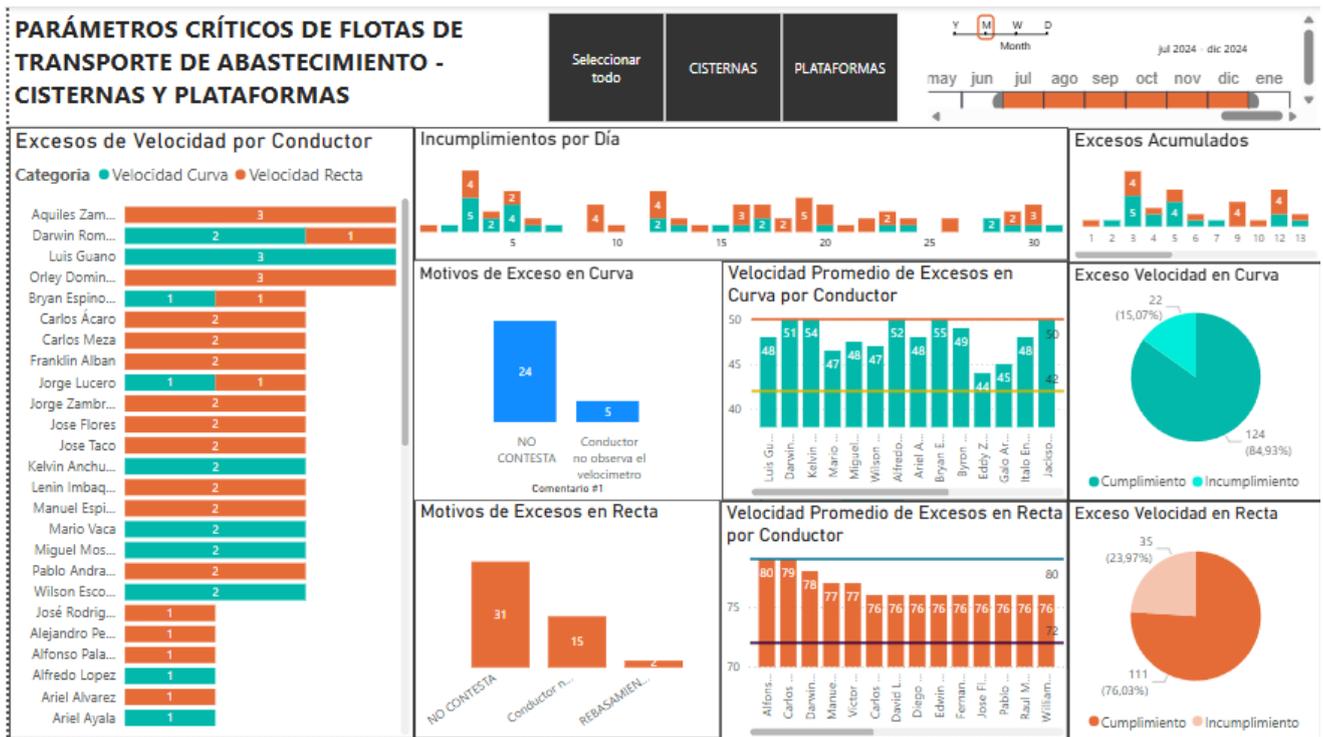


**Nota.** Elaborado en R utilizando datos de registros de plataforma tracklink y ontrack.

El árbol de decisiones de la Figura 3.14 muestra cómo las variables independientes (desviación detectada, somnolencia, prueba de alcohol positiva y alto riesgo de Sobereye) afectan para que se produzcan las infracciones por exceso de velocidad registradas en el colectivo de distribución. Cada nodo representa una condición para una variable, dividiendo los datos en subgrupos según el valor de la variable. Los nodos finales (hojas) contienen la predicción de la tasa promedio de incidentes de exceso de velocidad para este grupo de Distribución. El modelo utiliza métodos ANOVA para reducir la variabilidad dentro de los nodos y aumentar la discriminación de nodos. Los valores de la tabla muestran la velocidad media de los grupos resultantes, explicando así la influencia relativa de las variables sobre el fenómeno en estudio.

**Figura 3.15**

**Propuesta de Dashboard de control para los excesos de velocidad colectivo de Distribución.**



**Nota.** Elaborado en Power BI utilizando datos de registros de plataforma tracklink.

La figura 3.15 muestra el prototipo de un dashboard diseñado para monitorear los incumplimientos de velocidad de conductores en la flota de transporte de distribución, detallando excesos en curva y recta. Los gráficos permiten visualizar de forma clara el número total de excesos de velocidad cometidos por cada conductor, representados en barras para ambas categorías de

velocidad, y distribuidos a lo largo del período de observación seleccionado.

El dashboard destaca aquellos conductores que presentan más incumplimientos, ofreciendo un desglose por día y categorizando los excesos en curva y recta. También se presentan gráficos circulares que muestran el porcentaje de cumplimiento e incumplimiento de los conductores, facilitando la comparación y evaluación de cada uno. Los diagramas adicionales permiten identificar los motivos detrás de los excesos y la velocidad promedio de los excesos, brindando información útil para tomar acciones correctivas. Esto permite una gestión eficiente y en tiempo real de la seguridad y el comportamiento de los conductores, ayudando a identificar puntos críticos para mejorar.

## Capítulo 4

## **4.1 Conclusiones y recomendaciones**

### **4.1.1 Conclusiones**

- Mediante la limpieza y organización de los datos, se logró corregir errores que afectaban la calidad de los mismo. Lo cual ayuda a garantizar que los análisis realizados sean más precisos y útiles para el desarrollo de los objetivos planteados.
- Se pudo evidencia que las variables más importantes incluidas en el tablero GIS fueron un apoyo para un control eficiente de la seguridad operacional y vial de la empresa comercializadora de GLP puesto que se evidencio un crecimiento en la conciencia vial y operacional de los colaboradores y operadores de dicha empresa, a través de estos controles se evidenció la falta de compromiso al iniciar el proceso de control, además se notó una resistencia al cambio de mantener un control más riguroso de las actividades de operación y transporte.
- La definición de los indicadores demostró ser una herramienta muy práctica para medir el desempeño de los trabajadores en términos de seguridad. Estos indicadores también ayudaron a identificar puntos críticos de mejora y proporcionaron información valiosa para implementar medidas de prevención más efectivas.
- Con el modelo predictivo, se logró anticipar situaciones de riesgo. Lo que significa que la empresa ahora cuenta con una herramienta para planificar mejor y tomar mejores decisiones para evitar incidentes graves, beneficiando al personal y a la empresa.

#### **4.1.2 Recomendaciones**

- Mantener un monitoreo constante, es decir que los indicadores diseñados se utilicen de manera constante para garantizar que los resultados sigan siendo efectivos y se puedan adaptar a futuros cambios.
- Capacitar a los trabajadores, se sugiere realizar capacitaciones periódicas para asegurar la correcta implementación de las nuevas medidas de seguridad.
- Ampliar el alcance del modelo, ya que, aunque el enfoque principal del modelo fue la seguridad vial, éste podría explorar otras áreas de la empresa y mejorar la eficiencia en general.
- Revisar la calidad de los datos, es decir, realizar revisiones más frecuentes de las bases de datos para poder mantener su confiabilidad.

## Referencias

Gobierno Nacional garantiza el normal abastecimiento de Gas Licuado de Petróleo (GLP) a escala nacional – EP PETROECUADOR. (s/f). Eppetroecuador.ec. Recuperado el 15 de octubre de 2024, de <https://www.eppetroecuador.ec/?p=7727>

Chaparro, D. (2023, marzo 29). Análisis y Desglose de Accidentes en Campos Petroleros Hoy y Ayer - Tawney, Acosta & Chaparro P.C. Tawney, Acosta & Chaparro P.C; Tawney, Acosta & Chaparro P.C. <https://tacinjurylaw.com/es/blog/oil-field-accident-today-yesterday-analysis-breakdown/>

(S/f). Gob.ec. Recuperado el 15 de octubre de 2024, de [https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas\\_Economicas/Estadistica%20de%20Transporte/2024/i\\_trimestre/2024\\_RESULTADOS\\_SINIESTROS\\_IT.pdf](https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_Economicas/Estadistica%20de%20Transporte/2024/i_trimestre/2024_RESULTADOS_SINIESTROS_IT.pdf)

Mantilla, I., & Pazan, C. (2022, junio 6). 272 emergencias por fuga de GLP se registraron durante el 2022, en Quito. El Comercio. <https://www.elcomercio.com/actualidad/272-emergencias-por-fuga-de-glp-se-registraron-durante-el-2022-en-quito.html>

**Estadísticas de Transporte (ESTRA). Gob.ec. Recuperado el 24 de octubre de 2024, de [https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas\\_Economicas/Estadistica%20de%20Transporte/2023/ii\\_trimestre/2023\\_RESULTADOS\\_SINIESTROS\\_IITRIMESTRE.pdf](https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_Economicas/Estadistica%20de%20Transporte/2023/ii_trimestre/2023_RESULTADOS_SINIESTROS_IITRIMESTRE.pdf)**

(S/f). Edu.ec. Recuperado el 24 de octubre de 2024, de <https://www.dspace.espol.edu.ec/handle/123456789/53456>

Industria del GLP: ¿En qué Sectores Interviene? (2024, marzo 1). SEMMAQ SAC; SEMMAQ.

<https://semmaq.com/industria-del-glp/>

Noticias, E. G. (2020, enero 23). *¿Qué medidas de seguridad debe tener un vehículo*

*para transportar GLP?* • El Gas Noticias. <https://elgasnoticias.com/que-medidas-de-seguridad-debe-tener-un-vehiculo-para-transportar-glp/>

¿Qué es el GLP? (2017, julio 1). GASNOVA. [https://www.gasnova.co/sobre-el-glp/que-es-el-](https://www.gasnova.co/sobre-el-glp/que-es-el-glp/)

[glp/](https://www.gasnova.co/sobre-el-glp/que-es-el-glp/)

Qué es el Gas Licuado del Petróleo. (2024, julio 2). Enerlogix.org.

<https://www.enerlogix.org/blog/gas-natural/que-es-el-gas-licuado-del-petroleo>

Vista de El riesgo en el almacenamiento de GLP en el Ecuador. (s/f). Edu.ec. Recuperado el 25

de noviembre de 2024, de

<https://revistas.uide.edu.ec/index.php/innova/article/view/331/548>

Prácticas de seguridad y eficiencia del GLP en areneras y asfalteras. (2024, mayo 2). Unigas.

<https://www.unigas.com.co/blog/practicas-de-seguridad-y-eficiencia-del-glp-en-areneras-y-asfalteras/>

Cavazos-Arroyo, J., Pérez-Armendáriz, B., & Mauricio-Gutiérrez, A. (2014). Afectaciones y

consecuencias de los derrames de hidrocarburos en suelos agrícolas de Acatzingo,

Puebla, México. *Agricultura Sociedad y Desarrollo*, 11(4), 539–550.

[https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1870-54722014000400006](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1870-54722014000400006)

Marketing. (2021, mayo 6). ▷ Seguridad Industrial ¿Qué es y para que sirve? Objetivos. EDS

Robotics. <https://www.edsrobotics.com/blog/seguridad-industrial-que-es/>

Conciliac. (2023, julio 26). Conoce las 6 ventajas del machine learning en la gestión de datos.

Conciliac EDM. <https://conciliac.com/es/conoce-las-6-ventajas-del-machine-learning-en-la-gestion-de-datos/>

Aprendizaje automático de predicción de fallas: uso de aprendizaje automático para encontrar fallas antes de que ocurran. (s/f). Onupkeep. Recuperado el 25 de noviembre de 2024, de

<https://upkeep.com/es/learning/machine-learning-to-find-failures/>

Qué es: Bosque de aislamiento. (2024, julio 24). LEARN STATISTICS EASILY.

<https://es.statisticseasily.com/glossario/what-is-isolation-forest/>

Bergmann, D., & Stryker, C. (2024, agosto 29). What is an autoencoder? IBM.com.

<https://www.ibm.com/topics/autoencoder>

Gallegos, F. R. E. (2018). MODELO DE GESTIÓN DE EMERGENCIAS MAYORES EN LA INDUSTRIA DEL GAS Y PETRÓLEO EN EL ECUADOR. Universidad Internacional SEK.

<https://repositorio.uisek.edu.ec/bitstream/123456789/2844/1/Modelo%20de%20Gesti%C3%B3n%20de%20Emergencias%20en%20la%20Industria%20del%20Gas%20y%20Petr%C3%B3leo.pdf>

Peña, D. (2002). Análisis de datos multivariantes. Researchgate.net.

[https://www.researchgate.net/publication/40944325\\_Analisis\\_de\\_Datos\\_Multivariantes](https://www.researchgate.net/publication/40944325_Analisis_de_Datos_Multivariantes)

López, C. P. (2004). Técnicas de Análisis Multivariante de Datos. Pearson Education, S.A.

[https://gc.scalahed.com/recursos/files/r161r/w25172w/Tecnicas\\_de\\_analisis\\_multivariante.pdf](https://gc.scalahed.com/recursos/files/r161r/w25172w/Tecnicas_de_analisis_multivariante.pdf)

Montero Granados, R (2016): Modelos de regresión lineal múltiple. Documentos de Trabajo en Economía Aplicada. Universidad de Granada. España.

[https://www.ugr.es/~montero/matematicas/regresion\\_lineal.pdf](https://www.ugr.es/~montero/matematicas/regresion_lineal.pdf)

Aprendizaje Automático. (2025). Hewlett Packard Enterprise.

<https://www.hpe.com/lamerica/es/what-is/machine-learning.html>

Garrido Agenjo, Ó. A. (2017). Aplicación de técnicas de Cluster al análisis de responsabilidad de los conductores en accidentes de tráfico. Universidad Politécnica de Madrid.

[https://oa.upm.es/48075/1/TFG\\_OSCAR\\_ARTURO\\_GARRIDO\\_AGENJO.pdf](https://oa.upm.es/48075/1/TFG_OSCAR_ARTURO_GARRIDO_AGENJO.pdf)