

Master en Business Analytics

Tema:

**Business Analytics aplicado a la operación y
rentabilidad de TEXRELL**

Trabajo Final de Máster

Presentado por:

DANIEL SIMON

CRISTIAN PATZLAFF

M. FERNANDA ROMERO

JORGELINA ANTONARAKIS

Dirigido por:

VICTOR MANUEL YESTE MORENO

VICENTE CASTILLO FAULI

Julio 2025

Resumen

Este trabajo de fin de Máster tiene como objetivo principal aplicar técnicas de Business Analytics en la empresa Texrell, el nombre de la empresa es ficticio, los datos son obtenidos de una empresa que radica en Argentina, dedicada al sector petrolero, para optimizar la planificación de los recursos y mejorar la rentabilidad de sus contratos. A través de un enfoque que combina análisis descriptivo, predictivo y prescriptivo, se busca transformar datos operativos en información útil que guíe la toma de decisiones estratégicas.

El análisis se estructura en tres fases: una fase descriptiva que permite explorar visualmente el desempeño histórico de contratos y uso de recursos, para identificar patrones y entender el comportamiento pasado. Le continúa una fase predictiva que se enfoca en estimar el margen de rentabilidad de futuras operaciones utilizando Árboles de decisión. Este modelo permite predecir, a partir de información conocida antes de ejecutar el servicio, y observar si es rentable o no. Esto permitirá distinguir de forma precisa cuales, de ellos, generan mayores beneficios, cuáles operan con un margen reducido y cómo se distribuye el uso de recursos en cada uno de estos servicios, facilitando la optimización estratégica. Y por último una fase prescriptiva orientada a la propuesta de acciones concretas como reasignación de equipos, renegociación de contratos o rediseño de servicios.

Para la preparación y análisis de los datos, se utilizó el lenguaje de programación Python, especialmente en la limpieza y tratamiento de conjunto de datos descargados desde reportes de SAP de la empresa. Esta integración técnica permitió estructurar las variables claves necesarias para entrenar los modelos predictivos y alimentar las visualizaciones interactivas.

El resultado al que se quiere arribar es un sistema de apoyo a la decisión que permita identificar contratos críticos, simular escenarios de mejora y dotar a Texrell de herramientas analíticas aplicables a otras áreas operativas. El análisis se alinea con las tendencias del sector energético hacia una mayor eficiencia, control de costes y toma de decisiones basada en datos.

Palabras clave: sector petrolero, rentabilidad de contratos, análisis, toma de decisiones, control de costes, planificación de recursos, eficiencia operativa.

Abstract

The main objective of the Master's Thesis is to apply Business Analytics techniques to the company Texrell (a fictitious name). The data is obtained from a company based in Argentina, dedicated to the oil sector, with the aim of optimizing resource planning and improving the profitability of its contracts. Through an approach that combines descriptive, predictive, and prescriptive analysis, the goal is to transform operational data into useful information that guides strategic decision-making. The analysis is structured into three phases:

A descriptive Phase that allows for a visual exploration of the historical performance of contracts and resource usage, identifying patterns and understanding past behaviour. This is followed by a Predictive Phase focused on estimating the profit margin of future operations using Decision Trees. This model enables the predictions based on information available prior to service execution, allowing assessment of whether an operation is profitable or not. It helps accurately identify which services generate higher returns, which operate narrower margins, and how resource usage is distributed across them, facilitating strategic optimization. Finally, a Prescriptive Phase is oriented towards proposing concrete actions such as equipment reallocation, renegotiation contract, or service redesign.

For data preparation and analysis, Python programming language was used, particularly, for the cleaning and processing of datasets downloaded from the company's SAP reports. This technical integration allowed the structuring of key variables necessary to train predictive models and feed interactive visualizations. The expected outcome is a decision support system that allows the identification of critical contracts, the simulation of improvement scenarios, and equips Texrell with analytical tools applicable to other operational areas. The analysis aligns with the energy sector's trends towards greater efficiency, cost control, and data-driven decision-making

Keywords: Oil Sector, Contract profitability, Analysis, Decision-making, Cost Control-Resource Planning, Operational Efficiency

Contenido

1.	Introducción	1
1.1.	Objetivo de Desarrollo de Sostenibilidad	1
1.1.1.	Contexto Operativo	1
1.1.2.	Materialidad y ODS prioritarios:	2
1.1.3.	Objetivos y metas para el año 2030	2
1.1.4.	Hoja de Ruta	3
1.1.5.	Gobernanza y financiación	3
1.1.6.	Seguimiento y rendición de cuentas	4
1.1.7.	Beneficios esperados	4
1.2.	Justificación	4
1.3.	Problema y Finalidad	5
1.4.1.	Objetivo General	5
1.4.2.	Objetivos Específicos	5
1.5.	Descripción de la Empresa Texrell	6
1.5.1.	Recursos	7
1.5.2.	Cadena de Valor	8
1.5.3.	Diagnóstico de la situación, DAFO	12
1.5.4.	Análisis Externo	14
2.	Marco teórico	15
2.1.	Introducción	15
2.2.	Business Analytics	15
2.2.1.	Analítica descriptiva:	15
2.2.2.	Analítica predictiva:	16
2.2.3.	Analítica prescriptiva:	16
2.3.	Data Driven	16
2.3.1.	Cultura Data Driven	16
2.3.2.	Ventajas de estrategia data driven	17
2.4.	La Integración del Sistema ERP y las Llamadas de Servicio	18
2.4.1.	SAP	19
2.4.2.	Llamadas de Servicios	20
2.5.	Marketing digital	20
2.6.	Uso de API	21
2.7.	Tipos de API	21
2.8.	Dashboards	22

2.9.	Machine Learning.....	23
2.9.1.	Tipos de modelos de Machine Learning.....	23
2.9.2.	Análisis Exploratorio de Datos (EDA)	25
3.	Metodología	27
3.1.	Objetivos e Hipótesis	27
3.1.1.	Objetivos.....	27
3.1.2.	Hipótesis	27
3.2.	Descripción de los datos.....	28
3.2.1.	Delimitación de factores:	28
3.2.2.	Delimitación de problema:	28
3.2.3.	Delimitación de datos a utilizar:.....	29
3.3.	Tratamiento de los datos.....	30
3.3.1.	Definición de la metodología de tratamiento de datos:.....	30
3.3.2.	Metodología empleada para el tratamiento de datos:	30
3.4.	Modelado y técnicas	31
3.5.	Evaluación del modelo.....	32
3.6.	Herramientas utilizadas.....	33
3.6.1.	Python	33
3.6.2.	Visual Studio Code	33
3.6.3.	Google Docs	34
3.6.4.	Google Sheets	34
3.6.5.	Power Bi	34
3.7.	Participantes	35
3.7.1.	Responsable de coordinación	35
3.7.2.	Analista de datos	35
3.7.3.	Científico de datos	35
3.7.4.	Analista visual de datos	35
4.	Resultados.....	36
4.1.	Modelo de Predicción Random Forest.....	36
4.2.	Dashboard	38
4.2.1.	Evaluación Financiera	38
4.2.2.	Contratos Deficitarios.....	39
4.2.3.	Duración de Contratos	42
4.2.4.	Llamadas de servicio	45
5.	Validación de Hipótesis.....	48

5.1.	H1: El análisis económico y operativo permite identificar patrones del comportamiento de los contratos que ayuden a mejorar la rentabilidad de la empresa Texrell.	48
5.2.	H2: El modelo de predicción Random Forest permite predecir el margen estimado de los contratos futuros de la empresa.	49
5.3.	H3: El dashboard elaborado permite generar insights efectivos para la toma de decisiones de Texrell.	49
6.	Conclusiones	51
7.	Limitaciones y futuras líneas de investigación	54
7.1.	Limitaciones	54
7.2.	Futuras líneas de investigación.	54
8.	Acrónimos	56
9.	Referencias bibliográficas	58
10.	Anexos	61

Índice de Ilustraciones

Ilustración 1:	Logo diseñado para TEXRELL	6
Ilustración 2:	Cadena de Valor de Texrell	12
Ilustración 3:	Modelo de predicción	37
Ilustración 4:	<i>Visualización de Rentabilidad por Contrato, por Equipo y por Provincia.</i>	39
Ilustración 5:	Visualización de Estado de Rentabilidad de los Contratos	39
Ilustración 6:	Evolución en el tiempo del estado de los contratos	40
Ilustración 7:	Tipo de contratos por Equipo	41
Ilustración 8:	Contratos deficitarios por provincia	41
Ilustración 9:	Contratos deficitarios por cliente	42
Ilustración 10:	Duración de Contratos	43
Ilustración 11:	Rendimiento de contratos por duración	43
Ilustración 12:	Cliente por rango de duración y estado de contrato	44
Ilustración 13:	Importe, coste y margen % por rango de duración	44
Ilustración 14:	Distribución anual de Llamadas de Servicios en Base a clientes y Unidades de Negocio	45

1. Introducción

En la economía contemporánea, impulsada cada vez más por el valor de los datos, las técnicas de Business se han consolidado como un componente indispensable para la toma de decisiones en organizaciones de elevada complejidad. Al analizar de forma sistemática grandes volúmenes de información, las empresas no solo obtienen una evaluación rigurosa de su desempeño pasado, sino que también acceden a proyecciones fundamentadas que facilitan la planificación estratégica y la anticipación de escenarios futuros. Nuestro trabajo desarrolla un proyecto de análisis de negocio aplicado al sector del petróleo, mediante el estudio de la compañía ficticia Texrell. El propósito es optimizar la asignación de recursos y al mismo tiempo maximizar la rentabilidad de aquellos contratos de mayor envergadura operativa. Para ello, se recurre a técnicas avanzadas de análisis y visualización de datos y a la construcción y elección de un modelo predictivo que permite respaldar la decisión con evidencia cuantitativa más sólida.

1.1. Objetivo de Desarrollo de Sostenibilidad

El ODS se centra en ser una de las 17 metas de la ONU. Cada uno de sus objetivos describe un reto concreto, presentamos en este trabajo un enfoque integrado a Texrell para oportunas mejoras.

1.1.1. Contexto Operativo

La empresa se centra alrededor de un 85% del mercado nacional sobre actividades de desmontaje, transporte y montaje de equipos de perforación. Si tuviéramos que mencionar cual es la principal fuente de emisiones directa, ésta procede del diésel consumido por grúas y camiones, este es uno de los puntos críticos que menciona la Agencia Internacional de la energía y cuyo objetivo es reducirlo a la mitad para el año 2030 (*Worland, 2024*).

La empresa dispone de plataformas como SAP y RCV suministran esos datos que se necesitan para medir la geolocalización y la huella por servicio en tiempo real (*SAP SE, 2024*).

En el ámbito social, se ha hecho énfasis en destacar las comunidades mapuches que han sido afectadas por vaca muerta, haciendo énfasis en la consulta y la compra local (*Vergez & Nawel, 2023*).

1.1.2. Materialidad y ODS prioritarios:

- Descarbonización logística (ODS 7 y 13), el diésel de grúas y camiones es la mayor fuente de CO₂, rebajando reduce emisiones y gastos de combustible (*Worland, 2024*).
- Circularidad de Insumos (ODS 12), Refinar aceites y reciclar neumáticos convertir los residuos en materia prima y evitar compras de insumos vírgenes (*Martínez, 2021*).
- Trabajo digno y seguridad (ODS 8), apunta a menos accidentes y salarios más justos refuerzan la productividad y el compromiso de más de 500 operarios.
- Innovación y gobernanza digital (ODS 9 Y 16) Tanto SAP como RCV realizan el rastreo en tiempo real ofreciendo datos auditables (*SAP SE, 2024*).
- Relación Comunitaria (ODS 17), las alianzas con las comunidades mapuches y operadoras de Vaca Muerta legitiman operación y generan el empleo local (*Vergez & Nawel, 2003*).

1.1.3. Objetivos y metas para el año 2030

- Elevar el 40% las horas de servicio con grúas eléctricas y recortar un 50% las emisiones absolutas de CO₂ (*Worland, 2024*).

- Alcanzar un 80% de aceites hidráulicos refinados y lograr valorizar el 70% de los neumáticos que estén fuera de uso (Martínez, 2021).
- Reducir la tasa de accidentes y asegurar el salario digno para los empleados.
- Multiplicar la oferta laboral para los locales destacando la comunidad mapuche (*Vergez & Nawel, 2023*). Publicar todos los años un informe ESG, que traiga consigo los estándares GRI-TCFD, sustentado en los datos SAP-RCV (SAP SE, 2024).

1.1.4. Hoja de Ruta

- 2025 piloto de diésel, HVO 20% y sensores Iot en grúas para minimizar el ralenti (Karavalakis et al, 2022)
- 2026: contrato de refinados de aceites y firma de un PPA solar de 5 MW para las bases de Neuquén y Añelo (Tourinho, 2023).
- 2027. Incorporación de tres grúas híbridas de grandes tonelajes.
- 2028 despliegue de SAP Sustainability Control Tower para calcular la huella por transacción (SAP SE, 2024).
- 2029: electrificación del 50% de la flota ligera e instalación de cargadores rápidos en todas las bases.
- 2030: verificación de neutralidad de carbono bajo la norma ISO 14064-3. (ISO, 2019).

1.1.5. Gobernanza y financiación

Cada tres meses un comité revisará los avances en base a reducción de CO2 y en seguridad (*Ecles&Taylor, 2023*).

1.1.6. Seguimiento y rendición de cuentas

Los datos que ya capturan SAP y RCV se volcaran en un Power BI actualizado cada mes y verificado por un auditor externo una vez al año, tal como recomienda la guía de aseguramiento de GRI (*GRI, 2021*).

1.1.7. Beneficios esperados

Con más vehículos eléctricos y rutas afinadas, Texrell calcula un ahorro cercano al 15% del combustible y mantenimiento, además de menos emisiones y menos ruido en Añelo y Rincón de los Sauces (*IEA, 2024*). Mostrar estos resultados con métricas ESG claras fortalece la mano de las licitaciones de YPF y otras empresas. Se busca un ambiente de trabajo más seguro y moderno que ayuda a retener a los operadores de grúas y choferes de camiones, un perfil cada vez más escaso en la Cuenca Neuquina (*PRI, 2023*).

1.2. Justificación

En el negocio de Oil & Gas (sobre todo en Argentina, donde la economía fluctúa con frecuencia y las operaciones son especialmente complejas), gestionar los datos con rigor y anticiparse a los cambios en la demanda es decisivo para sostener el crecimiento de cualquier economía. Sin embargo, muchas empresas siguen sin transformar el caudal de información que generan a diario en conocimiento útil para tomar decisiones seguras. Las técnicas del análisis de negocio permiten afrontar ese desafío al mejorar la asignación de recursos, detectar contratos con márgenes negativos y proponer ajustes estratégicos que repercuten de inmediato en la rentabilidad y la eficiencia. El proyecto que se presenta convierte los datos operativos de la empresa en un sistema de soporte a la decisión capaz de señalar, en tiempo real, los puntos críticos de la operación, proyectar la demanda futura y optimizar el uso de recursos. Al incorporar un modelo predictivo, la empresa dispondrá de una herramienta analítica que no sólo identificar áreas de mejora, sino que también permitirá simular distintos escenarios y respaldar cada decisión con evidencia cuantitativa, reduciendo así el riesgo y el coste operativo.

1.3. Problema y Finalidad

Texrell opera en un segmento especialmente expuesto a los vaivenes del mercado energético. Cada día despliega equipos, personal, logística para atender contratos de servicio cuyo margen puede variar con la misma rapidez con que cambian los precios de crudo. Cuando la compañía carece de un sistema capaz de leer a tiempo lo que ocurre en sus propios datos, la planificación se vuelve inverosímil y los recursos se van asignando según la vorágine de los tiempos operativos sin tener consideración en como deberían ser asignados de una manera más homogénea.

En SAP se almacena un caudal significativo de información como órdenes de trabajo, tiempos de operación, las actividades que identifican el costo dentro de la llamada de servicio, el consumo de materiales, los movimientos de flota, mantenimiento etc. Sin embargo, ese repositorio sigue siendo pasivo, por que la ausencia de modelos que crucen las variables y anticipen tendencias no se está dando actualmente y esto dificulta señalar qué contratos erosionan la rentabilidad, prever cuellos de botella o dimensionar la logística cuando la demanda acelera.

Este proyecto propone sacar partido de esta materia informativa en crudo mediante técnicas analíticas, construyendo un sistema que transforme el histórico operativo en alertas tempranas y pronósticos fiables. Dicho sistema servirá de apoyo a la decisión: señalará en tiempo real los puntos críticos clasificará los contratos según su aportación económica y recomendará la asignación óptima de equipos y recursos, reforzando así su posición competitiva dentro de la industria petrolera.

1.4. Objetivos

1.4.1. Objetivo General

Analizar el desempeño económico y operativo de la empresa Texrell, con el fin de optimizar la toma de decisiones, mediante el uso de herramientas de Business Analytics y modelos de predicción que ayuden a mejorar la rentabilidad por contrato.

1.4.2. Objetivos Específicos

1. Aplicar modelos de predicción para estimar la rentabilidad futura de contratos, anticipando si es beneficioso realizar el contrato.

2. Evaluar la rentabilidad de cada contrato y unidad de negocio, mediante la comparación de ingresos y costos operativos.
3. Detectar contratos con márgenes bajos o resultados deficitarios que puedan ser candidatos a renegociación o reestructuración.
4. Identificar tendencias de rentabilidad de los contratos según la duración de estos.
5. Estudiar la distribución anual de llamadas de servicios registradas, en base a clientes y unidades de negocio con gran carga operativa.

1.5. Descripción de la Empresa Texrell

Texrell (nombre ficticio) abrió sus puertas en 1997 y eligió Neuquén como sede central, justo en el corazón de vaca muerta, el polo petrolero más dinámico del país. Esa decisión temprana le permitió crecer al compás del desarrollo de la cuenca neuquina y posicionarse como líder en Argentina, Pérez (2021). La oferta de Texrell se articula en unidades de negocio bien definidas como lo son Transportes de Cargas Solidas, grúas, Vactor, Tráileres, Administración, Mantenimiento, Transporte de Cargas Liquidas, Almacenes, Eólicos, Servicios Viales, Desmonte, traslado y Montaje, etc. Uno de los pilares competitivos es su parque de maquinaria de última generación, grúas telescópicas, manlifts, y desde mayo la primera grúa eléctrica del país. Esta renovación constante refuerza su capacidad de afrontar proyectos de gran envergadura con clientes demandantes como lo es YPF. La estrategia corporativa se enfoca en garantizar operaciones seguras, rentables y ambientalmente responsables. Su experiencia se basa en casi tres décadas apuntando a tecnología de vanguardia.

***Ilustración 1:** Logo diseñado para TEXRELL*



Fuente: Elaboración propia

1.5.1. Recursos

a) Recursos Humanos

Texrell cuenta con un equipo altamente calificado para llevar adelante sus servicios como un directorio dirigido por sus dueños y dos gerentes generales. La gestión operativa está liderada por un equipo compuesto por gerentes de operaciones, logística y Proyectos, quienes se encargan de coordinar los contratos activos y optimizar los recursos en cada operación.

La empresa cuenta con un equipo técnico especializado en mantenimiento, operación de grúas, transporte de cargas sólidas y líquidas, así como supervisores de campo y Técnicos de seguridad e Higiene, para garantizar la seguridad y la calidad en cada servicio. Además, dispone de personal administrativo y comercial que gestiona los procesos de certificación, facturación y gestión de contratos.

También realiza capacitaciones periódicas para su equipo en materia de seguridad, eficiencia operativa y manejo de equipos pesados, asegurando que cada operación cumpla con los estándares internacionales del sector petrolero.

b) Recursos materiales

Dispone de un amplio parque de maquinaria de última tecnología, diseñado para cubrir las necesidades operativas del sector Oil & Gas. Entre los recursos materiales más destacados se encuentran:

- Grúas telescópicas. Capacidades de entre 20 y 500 toneladas, modelos Demag, Tadano Faun y Liebherr. La 1º grúa eléctrica del país (2025).
- Flota de Transporte: Vehículos especializados para cargas sólidas, incluyendo materiales peligrosos. Para destacar camiones americanos MACK.
- Equipos de perforación: Máquinas de alta tecnología para operaciones de montaje y desmontaje en campos petrolíferos.
- Gestión de Almacenes: Instalaciones en distintas provincias para el almacenamiento y distribución eficiente de recursos operativos.
- Tráileres, luminarias y generadores que alquila.
- Eólicos con su transporte incluido

c) Recursos intangibles

Hoy en día, la empresa cuenta con una infraestructura tecnológica avanzada que respalda sus operaciones en el sector petrolero. Entre los recursos intangibles más destacados se encuentran:

- Sistema de información (ERPS: SAP): Gestiona la planificación de recursos, el seguimiento de contratos, control de datos y logística, sobre todo la base estructural se fija en las llamadas de servicios.
- Relaciones Estratégicas: Alianzas comerciales con grandes operadoras del sector como YPF y otros actores clave en el mercado petrolero.
- Certificaciones Internacionales: Cumplimiento de normas internacionales en seguridad y eficiencia operativa, lo cual refuerza su posición competitiva.
- Tecnología para Optimización: Software para simulación de escenarios y visualización de datos en tiempo real.
- Políticas de RSE: Programas de Responsabilidad Social Empresarial enfocados en sostenibilidad y compromiso en el sector local.

1.5.2. Cadena de Valor

Se conoce a la cadena de valor como un concepto teórico estratégico que abarca todas las fases del proceso de un negocio, dándole un valor empresarial, esto permite poder dilucidar el modo en que se desarrollan las actividades de una organización generando un valor al producto.

A continuación, se describirán las actividades clave relacionadas con el negocio de logística y medios de elevación para el sector petrolero, optimizando recursos y mejorando la rentabilidad en los servicios ofrecidos a sus clientes. Esta estrategia es fundamental en sectores de alta exigencia como el energético, donde la eficiencia operativa y la minimización de costos son determinantes para la competitividad (Christopher, 2016).

a) Actividades Primarias

- **Logística de entrada**

En Texrell, la logística de entrada abarca la recepción y el transporte de materiales y equipos desde proveedores hasta los puntos operativos, muchas veces las locaciones de los diferentes yacimientos de petróleo. asegurando el cumplimiento de estándares de seguridad. Este proceso asegura el cumplimiento de estándares de seguridad, e implica una planificación estratégica de rutas, una gestión rigurosa de flotas e inventarios, y una verificación constante de las condiciones de transporte (Ballou, 2004). Además, la compañía ha implementado un sistema de trazabilidad llamado RCV (rastreo de vehículos) que permite conocer la ubicación de los vehículos en tiempo real, utilizando la tecnología de GPS y plataformas que permiten el monitoreo de la flota, lo que facilita una respuesta rápida ante cualquier imprevisto.

- **Operaciones**

Las operaciones representan el corazón de la firma en la industria petrolera. En esta área, se destacan tres actividades clave:

- ✓ Montaje y desmontaje de equipos de perforación y eólicos: desde sus inicios, Texrell se ha especializado en esa tarea, alcanzado un 85% de participación en el mercado argentino. Este liderazgo se debe a su capacidad para garantizar seguridad y eficiencia en cada proyecto.
- ✓ Manejo de grúas y equipos de elevación: dispone de un parque amplio de maquinaria moderna, que incluye grúas telescópicas y manlift. Esta tecnología de última generación le permite abordar proyectos de gran envergadura.
- ✓ Transporte de cargas peligrosas: tanto sólidas como líquidas, la compañía gestiona el traslado con altos estándares de seguridad y sobre la normativa vigente. Para ello cuenta con vehículos especializados y un personal capacitado.

- **Logística de Salida**

La logística de salida se enfoca en el transporte y la entrega de los equipos una vez finalizados los trabajos en locaciones. Este proceso es clave para mantener la continuidad operativa y la satisfacción del cliente, ya que implica coordinación precisa, cumplimiento de plazos pactados y verificación del estado de los materiales antes de su envío (Ballou, 2004). La empresa coordina cada traslado asegurando el cumplimiento de los plazos pactados y verificando el estado óptimo de los materiales antes de su envío. Su flota moderna y su capacidad de planificación le permiten adaptarse a las necesidades específicas de cada cliente, incluso en ubicaciones remotas y de difícil acceso.

- **Servicio**

El servicio post operativo es vital para la fidelización y continuidad del negocio (Parasuraman, Zeithaml & Berry, 1988). El mantenimiento preventivo y correctivo de la maquinaria se lleva a cabo por un equipo técnico altamente cualificado. Las inspecciones periódicas y las reparaciones en campo aseguran que los equipos funcionen correctamente, minimizando tiempos de inactividad. Además, se realizan auditorías de seguridad y calidad para cumplir con un nivel alto de seguridad.

b) Actividades Secundarias

- **Infraestructura y Mantenimiento**

Texrell cuenta con una infraestructura moderna respaldada por un sistema de mantenimiento preventivo, lo cual garantiza el correcto funcionamiento de su maquinaria y vehículos. Esta estrategia permite minimizar paradas no programadas y asegurar la operatividad continua, especialmente en proyectos de gran envergadura donde los costos por interrupciones son significativos (Sherwin, 2000). Las instalaciones están equipadas con talleres especializados para la reparación y actualización de equipos, además de áreas de almacenamiento de repuestos críticos teniendo en cuenta que se necesita ese stock ya que la mayoría de las grúas son de exportación.

Texrell cuenta con instalaciones distribuidas estratégicamente en diferentes puntos del país y fuera de él. Entre las más destacadas se encuentran operativas las bases en las ciudades de Neuquén, Bahía Blanca, Añelo, Chubut, Mendoza, así como su expansión

internacional en Chile. Estos espacios incluyen centros logísticos, almacenes y oficinas administrativas, facilitando la gestión y el soporte a las unidades de negocio.

- **Gestión de Recursos Humanos**

Becker, Huselid y Ulrich (2001) señalan que las empresas que invierten en el desarrollo continuo de su capital humano logran mejores resultados operativos y mayor retención del talento. El capital humano es un pilar fundamental en Texrell. La empresa no solo se enfoca en la capacitación constante de su equipo, sino también en fomentar un ambiente laboral seguro y colaborativo. Los programas de formación incluyen entrenamientos en seguridad industrial, manejo de maquinaria pesada y actualización en normativas del sector.

- **Administración y Finanzas**

Según García y Pérez (2021), la gestión administrativa eficaz es clave para maximizar la eficiencia operativa y financiera en empresas industriales. A través de un riguroso control de costos, una planificación detallada y el uso de herramientas digitales, la empresa optimiza la asignación de recursos y garantiza la rentabilidad de sus operaciones. Además, se realizan auditorías periódicas para asegurar el cumplimiento normativo y hay un equipo de certificación de servicios que se encarga del control, imputación en SAP y entrega de documentación al sector de facturación, dando una trazabilidad en sistema registrado en Órdenes de Ventas dentro de las llamadas de servicio del ERP.

- **Relaciones institucionales y Medio Ambiente**

Mantiene un fuerte compromiso con el entorno y las comunidades donde opera. Colabora con instituciones gubernamentales y organizaciones del sector para fortalecer la seguridad industrial.

Además, fomenta relaciones de respeto y colaboración con las comunidades mapuches que habitan en la zona petrolera, particularmente en Vaca Muerta y sus alrededores. Este vínculo se basa en el diálogo constante y la integración de prácticas que respeten su cultura y sus derechos sobre los territorios ancestrales. Este compromiso con el tejido social ha contribuido a la convivencia armónica y el respeto mutuo entre la industria y la

comunidad. Este enfoque se alinea con lo planteado por Porter y Kramer (2011), quienes sostienen que las empresas deben crear valor compartido integrando el desarrollo social y económico en sus estrategias de negocio.

Ilustración 2: Cadena de Valor de Texrell



Fuente: Elaboración propia.

1.5.3. Diagnóstico de la situación, DAFO

Antes de proponer mejoras o tomar decisiones importantes en una empresa, es fundamental entender en qué lugar se posiciona. El análisis DAFO es una herramienta que ayuda justamente a mirar con claridad los puntos fuertes y débiles de una organización, y también a estar atentos a las oportunidades o amenazas que vienen de afuera. En este caso, se aplicó a Texrell para tener una visión más completa de su situación actual, considerando tanto lo que ocurre dentro de la empresa como lo que pasa en el sector energético, que es altamente cambiante y competitivo.

Según Kotler y Armstrong, el análisis DAFO “permite adaptar la estrategia de una empresa a su entorno cambiante, evaluando tanto las capacidades internas como las condiciones del mercado”. En línea con esta idea, a continuación, se presentan los

principales factores que definen el posicionamiento actual de Texrell en su contexto operativo.

A) Fortalezas

- Liderazgo en el mercado de desmontaje, transporte y montaje de equipos de perforación.
- Flota moderna y actualizada con tecnología de última generación.
- Alianzas estratégicas con grandes operadoras como YPF.
- Cobertura operativa en múltiples provincias estratégicas de Argentina y en Chile.
- Certificaciones internacionales que garantizan la seguridad y eficiencia operativa

b) Oportunidades

- Expansión a nuevos mercados internacionales dentro de la región latinoamericana.
- Crecimiento en la demanda de servicios de transporte y perforación.
- Innovación tecnológica en equipos de perforación y grúas híbridas y eléctricas.
- Alianzas estratégicas con nuevas operadoras de petróleo y gas.

c) Debilidades

- Dependencia de contratos con grandes operadores del sector
- Dependencia del pago de Clientes importantes para la realización de gestiones de inversión, etc.
- Altos costos operativos asociados al mantenimiento de la flota.
- Falta de integración completa de datos para análisis predictivos.

d) Amenazas

- Fluctuaciones en el precio del petróleo que afectan la rentabilidad.
- Cambios regulatorios en materia ambiental y de transporte.
- Competencia emergente en el sector Oil & Gas

1.5.4. Análisis Externo

a) *Análisis del Sector*

El sector de petróleo y gas en Argentina representa un pilar fundamental en la economía nacional, siendo uno de los principales motores de desarrollo industrial y de energía. Según datos del Instituto Argentino de Petróleo y Gas, el mercado ha crecido en los últimos 10 años, impulsado por el incremento en la demanda de combustibles fósiles y la expansión de proyectos de extracción en yacimientos no convencionales, como Vaca Muerta.

La segmentación geográfica se concentra en las provincias como Neuquén, Añelo, Río Negro, Mendoza y Chubut, donde se encuentran los principales yacimientos de petróleo y gas, como también en expansión internacional como en el país chileno.

Las tendencias del mercado apuntan hacia una mayor demanda de servicios logísticos especializados, debido al aumento en la producción. Asimismo, se prevé una suba en la inversión en infraestructura y modernización de flotas para optimizar el transporte de equipos pesados y materiales peligrosos.

El contexto regulatorio también juega un papel clave en el sector. En los últimos años, el gobierno argentino ha impulsado políticas de incentivo para la inversión extranjera y el desarrollo de energías renovables, lo cual representa una oportunidad para Texrell de expandir sus servicios en nuevas áreas vinculadas a la energía sostenible.

En cuanto a la competencia, se identifican actores clave como TSB y Nabors, que dominan el mercado de Transporte y montaje de equipos en las principales cuencas petroleras. Texrell se diferencia por su flota moderna y su capacidad para realizar operaciones integrales, desde el transporte hasta el montaje y desmontaje de estructuras en campo.

Las estrategias competitivas en el sector se enfocan en la optimización de costos, la eficiencia tanto operativa como la capacidad para ofrecer servicios de alta calidad en entornos desafiantes. Texrell ha apostado por la digitalización de sus procesos y el uso del Business Analytics para identificar oportunidades de mejora en la planificación de recursos.

En conclusión, el análisis del sector Oil & Gas en Argentina evidencia un mercado en expansión, con grandes oportunidades para esta compañía en términos de crecimiento, optimización de recursos y la posibilidad de expandirse a nuevas áreas energéticas.

2. Marco teórico

2.1. Introducción

El marco teórico que sustenta este Trabajo de fin de Máster se centra en los conceptos de fondo sobre el Business Analytics, definido como el uso sistemático de datos, análisis estadísticos y tecnologías para mejorar la toma de decisiones en las organizaciones (Davenport & Harris, 2007). Esta disciplina combina el análisis de datos, estadística, visualización y tecnología para extraer información valiosa en entornos empresariales. A través de Business Analytics, Texrell podrá identificar patrones de comportamiento, anticipar tendencias del mercado y optimizar sus procesos operativos, logrando así una mayor competitividad en el sector petrolero de Vaca Muerta.

La implementación de Business Analytics permite a las empresas mejorar la toma de decisiones, optimizar recursos, reducir costos y maximizar la eficiencia operativa. Para alcanzar estos objetivos, se implementan diferentes tipos de análisis, cada uno con un enfoque y un propósito específicos.

2.2. Business Analytics

Business Analytics se fundamenta en la transformación de datos en insights accionables, apoyándose en tecnologías avanzadas para optimizar la toma de decisiones y anticipar tendencias empresariales (Davenport & Harris, 2007).

Se define se define como un proceso de análisis en el cual se transforman datos en información relevante para la toma de decisiones estratégicas. Este enfoque se sustenta en tecnologías, herramientas estadísticas y metodologías que permiten conocer en profundidad el funcionamiento de una empresa y prever escenarios futuros.

Los tres pilares fundamentales del Business Analytics son:

2.2.1. Analítica descriptiva:

La analítica descriptiva permite evaluar el desempeño pasado mediante la organización y visualización de datos, facilitando decisiones estratégicas basadas en evidencia (Davenport & Harris, 2007).

En el contexto de Texrell, esta fase permite evaluar el desempeño de los contratos, el uso de la maquinaria y la eficiencia en la logística de transporte.

2.2.2. Analítica predictiva:

La analítica predictiva, apoyada en modelos estadísticos y algoritmos de machine learning, es clave para anticipar riesgos y optimizar operaciones, reforzando la toma de decisiones proactivas (Davenport & Harris, 2007). En Texrell, se aplicará para predecir la demanda de servicios, estimar el desgaste de maquinaria y anticipar posibles cuellos de botella en la logística.

Modelos como Random Forest permitirán identificar variables críticas que afectan la rentabilidad de los contratos y la eficiencia operativa.

2.2.3. Analítica prescriptiva:

La analítica prescriptiva utiliza técnicas de optimización matemática y simulación para recomendar acciones específicas que mejoren el desempeño empresarial (Bertsimas & Kallus, 2020). En Texrell, esta fase estará orientada a:

Asignación de recursos: reubicación estratégica de grúas y vehículos para optimizar tiempos y reducir costes, asignándole al contrato que más los demande.

Simulación de escenarios: Evaluación de diferentes contratos para identificar decisiones que maximicen los beneficios.

2.3. Data Driven

2.3.1. Cultura Data Driven

Según Shmueli, Patel & Bruce (2017), la metodología Data Driven permite a las empresas tomar decisiones basadas en el análisis e interpretación de datos reales, obtenidos de diversas áreas del negocio. Esta forma de gestión reduce la dependencia en la intuición y minimiza los riesgos asociados a suposiciones no verificadas, incrementando así la objetividad y la precisión en la toma de decisiones.

Texrell está en proceso de adoptar una cultura data-driven, donde las decisiones se fundamentan en el análisis de datos objetivos y en tiempo real. Esta transformación permitirá a la empresa optimizar sus procesos operativos, reducir la incertidumbre en la

toma de decisiones y aumentar su capacidad de respuesta ante cambios en el mercado. La implementación de esta cultura se apoya en sistemas de información robustos como lo son SAP y Power BI, herramientas de visualización y técnicas de Machine Learning para la anticipación de escenarios críticos. Esta transformación orientada a los datos permite no solo mejorar la eficiencia operativa, sino también fortalecer las decisiones en cuanto a la asignación de recursos en los diferentes contratos.

2.3.2. Ventajas de estrategia data driven

a) Reducir errores y minimizar riesgos.

Texrell al contar con un procedimiento más informado, las decisiones que toma basadas en datos adquieren una mayor precisión en la planificación de recursos y una reducción en las incidencias operativas relacionadas con el transporte ya que apunta a asignar los recursos de forma eficiente en cada contrato según su nivel de complejidad.

b) Identificar nuevas oportunidades de mercado.

El enfoque Data Driven permite detectar patrones en la demanda de servicios y anticiparse a cambios en el mercado. En el contexto del sector petrolero, esto incluye identificar y capitalizar nuevas oportunidades en regiones con mayor expansión como es la Patagonia Argentina.

c) Optimizar procesos internos en la organización.

El análisis constante de datos operativos y comerciales de Texrell, permite identificar cuellos de botella en sus procesos tanto logísticos como financieros, optimizando la gestión y reduciendo la fuga de costos

d) Aportar una visión más completa de la empresa en tiempo real.

A través de indicadores claves de rendimiento, los KPIs y visualizaciones interactivas, Texrell puede monitorear en tiempo real el estado de sus contratos, la disponibilidad de equipos y el uso de recursos logísticos, permitiendo una gestión más ágil y precisa.

e) Mejora en la experiencia del cliente.

La capacidad de anticipar necesidades y optimizar los procesos logísticos incrementa la satisfacción del cliente, reduciendo demoras en los servicios de montaje y transporte, y asegurando una entrega más eficiente y segura de los equipos.

f) Ahorro de costos.

El enfoque Data - Driven permite identificar ineficiencias y optimizar la asignación de recursos, reduciendo costos operativos y mejorando la rentabilidad en cada proyecto. En Texrell, esto significa un uso más eficiente de la flota, menor gasto en mantenimiento y optimización de rutas si se asignan en los contratos de mayor utilidad.

2.4. La Integración del Sistema ERP y las Llamadas de Servicio

Los sistemas ERP (Enterprise Resource Planning) como SAP, Oracle, Odoo o NetSuite son herramientas de software que integran los departamentos de una empresa, permitiendo una gestión centralizada de ventas, producción, finanzas, recursos humanos, servicios, inventarios, compras, sueldos, pañol, entre otros (Monk & Wagner, 2012). Estos sistemas automatizan y optimizan las operaciones diarias, brindando una fuente única de información confiable para la toma de decisiones estratégicas (Davenport, 1998).

Los ERP actualmente se basan en tecnologías inteligentes como machine learning, bases de datos in memory, procesamiento de lenguaje natural e Inteligencia Artificial. Esto hace que las compañías sean más eficientes, tengan información estratégica empresarial actualizadas lo que permite ser competitivos en un ámbito que fluctúa rápido.

Puntos de beneficio de los ERP: Informes inmediatos, comparten bases de datos, agilidad y profundidad de información, un riesgo más bajo, mayor productividad e información estratégica actualizada

En el sector petrolero, donde opera Texrell, un ERP resulta esencial para gestionar los recursos, el sector comercial y el recurso humano. Dando una gran relevancia al inventario de equipos, la planificación del transporte de la maquinaria pesada y el control de contratos con grandes operadoras.

El sistema ERP de Texrell puede registrar datos operativos clave como:

- Movimiento de maquinaria pesada
- Control de entradas y salidas de inventario
- Asignación de recursos a cada contrato.
- Monitoreo en tiempo real de vehículos y equipos en campo.

2.4.1. SAP

SAP proviene de la abreviatura de la empresa, Systems, Applications, and Products, es un sistema de planificación de recursos empresariales (ERP) que permite integrar y gestionar sus procesos de negocio en un entorno centralizado y estandarizado. Su presencia global lo posiciona como un actor clave en la gestión empresarial a nivel mundial (Davenport, 1998).

En Texrell la gestión íntegra de la empresa se organiza mediante SAP, es utilizado para la administración y seguimiento de los servicios que se prestan en campo, especialmente aquellos relacionados con el transporte, montaje y certificación de servicios para la industria del petróleo y gas.

Los módulos fundamentales son:

- Comercial
- RRHH
- Sueldos
- Partes
- Operaciones
- Mantenimiento
- Compras
- Inventario

La característica de SAP en Texrell es que sus módulos se fundamentan en Actividades, éstas se basan en costos, están vinculadas a una Llamada de Servicio, la cual da una visualización de los recursos asignados a través de las actividades que contenga, éstas llamadas de Servicios se dividen en internas o externas. Las Internas pertenecen a Texrell y corresponden a la actividad interna de la compañía para que todo funcione normalmente y la externa corresponde al cliente y es un costo que será gestionado a través de una Orden

de Venta (OV), dentro de la Llamada de Servicio y que luego facturará el sector de Facturación.

Las llamadas de servicio en SAP permiten a Texrell llevar un control detallado de cada prestación, asegurando que se cumplen los requisitos operativos y contractuales establecidos con los clientes.

2.4.2. Llamadas de Servicios

Las Llamadas de Servicio son el núcleo de la operación en Texrell para gestionar los servicios prestados. Este proceso inicia con una solicitud de servicio que se realiza mediante un correo electrónico y se formaliza en SAP a través de una Llamada de Servicio.

Esta llamada incluye datos fundamentales como:

- *Cliente*: se especifica el socio de negocio al que se prestará el servicio.
- *Ubicación*: Se indica la provincia y locación donde se realizará el servicio.
- *Tipo de Servicio*: puede ser mensual u On Call (a demanda) o Stand By dependiendo de los términos del contrato.
- *Inspector*: En caso de que el contrato lo requiera.
- *Proyecto*: se relaciona con la llamada es la identificación interna del contrato del cliente para Texrell.

2.5. Marketing digital

El marketing digital en el sector Oil & Gas ha tomado un papel fundamental en la visibilidad y posicionamiento de empresas como Texrell. Según Deloitte (2022), la transformación digital en industrias tradicionales como el petróleo y gas es clave para mejorar la comunicación con clientes y socios, aumentando la eficiencia y agilidad en la transmisión de información. Las estrategias digitales permiten conectar con clientes, proveedores y operadores del sector de manera eficiente y en tiempo real. Para ello, se implementan plataformas digitales que facilitan la difusión de información clave sobre servicios, capacidad operativa y logros alcanzados en proyectos críticos.

Entre las principales herramientas se encuentran:

- LinkedIn: Focalizado en la conexión con líderes de la industria, partners estratégicos y contratación de talento especializado.
- Webinars y Conferencias Virtuales: Espacios digitales para presentar nuevas tecnologías, casos de éxito y compartir conocimiento técnico con actores clave del sector.
- SEO y SEM. Optimización en motores de búsqueda para captar clientes potenciales y aumentar la visibilidad en mercado clave.
- Instagram: a través de la gestión de una community manager se visualiza en las redes novedades como nuevos lazos económicos, visitas a fábricas, ingresos de nuevas grúas como la primera grúa eléctrica y silenciosa del país.
- E-mail Marketing: Comunicación directa con clientes y partners para informar sobre nuevos servicios, casos de éxito y actualizaciones operativas.

2.6. Uso de API

La implementación de esta estrategia SEO ofrece múltiples ventajas:

- Mayor visibilidad: logra ser encontrado más fácilmente por clientes potenciales en entornos digitales competitivos.
- Optimización de Costes: Al incrementar el tráfico orgánico, se reduce la necesidad de campañas pagas, mejorando el rendimiento de la inversión.
- Captación de Leads Cualificados: Las búsquedas específicas del sector atraen a clientes potenciales que buscan servicios especializados.
- Consolidación de la Marca: El posicionamiento en motores de búsqueda refuerza la percepción de la compañía como líder en el sector.
- Mejora continua: El análisis constante de métricas permite ajustar la estrategia en tiempo real para maximizar el rendimiento.

2.7. Tipos de API

Las API son esenciales para lograr una conectividad fluida entre sistemas y mejorar la eficiencia digital de las organizaciones (Serrano & Hernantes, 2020). La empresa ha integrado diversas APIs en sus procesos operativos para optimizar la gestión y la planificación de recursos. Estas interfaces de programación permiten una comunicación

que fluye entre sistemas internos y externos, mejorando la eficiencia y la capacidad de respuesta.

Hay diferentes APIs claves:

- API para control de flota: Ofrece una visión en tiempo real de la ubicación y el estado de los vehículos, permitiendo una planificación de rutas más eficiente y una reducción de tiempos de entrega.
- API para Gestión de Inventarios: Permite sincronizar el inventario de maquinaria pesada con los sistemas de planificación, asegurando que los recursos estén disponibles en el momento y lugar adecuado.
- API para Proveedores: Facilita la conexión directa con proveedores estratégicos, permitiendo actualizaciones automáticas de pedidos y seguimiento en tiempo real de las entregas.
- API para Visualización en Power BI: Integra datos operativos directamente en Power BI, lo que permitía a la empresa contar con dashboards interactivos y actualizados, optimizando la toma de decisiones en tiempo real.
- API para Llamadas de Servicios: Sincroniza en tiempo real las llamadas de servicios generadas desde SAP por los coordinadores, permitiendo una planificación eficiente de las asistencias técnicas y la movilización de recursos en campo.

2.8. Dashboards

La compañía utiliza dashboards dinámicos desarrollados en Power BI para supervisar y optimizar sus operaciones. Aquí se logra una visión interactiva y en tiempo real de las actividades críticas, lo que facilita una gestión más eficiente y orientada a resultados.

- **Dashboards Estratégicos**

Permiten al equipo directivo evaluar el rendimiento de los contratos, identificar riesgos y planificar expansiones. La información centralizada en Power BI facilita el análisis detallado de cada operación.

- **Dashboards Operativos**

Estos paneles muestran en tiempo real el estado de la maquinaria, el movimiento de flotas y el avance de los proyectos. Gracias a Power BI, los responsables de operaciones pueden ajustar los recursos rápidamente para maximizar la eficiencia.

- **Dashboards Analíticos**

A través de algoritmos de Machine Learning y visualización de datos, la empresa identifica patrones y optimiza procesos logísticos, proyectando la demanda y anticipando posibles inconvenientes, creando un camino para una sólida toma de decisiones.

2.9. Machine Learning

Machine Learning o también conocido como modelos de aprendizaje automático nos permitirá realizar predicciones y analizar nuestros datos por lo cual según Bishop (2006) lo define como “el estudio de algoritmos que mejoran su rendimiento en alguna tarea a través de la experiencia”. Por lo cual el machine learning actualmente es una herramienta fundamental en esta área.

Este tipo de modelos Domingos (2012) sostiene que la clave del aprendizaje automático radica en su capacidad de generalización, su habilidad para aplicar lo aprendido en un conjunto de datos a situaciones nuevas y no vistas. Esta generalización se logra mediante la construcción de modelos, que pueden ser ajustados, validados y optimizados con técnicas estadísticas y computacionales. A continuación, señalaremos algunos tipos de modelo de Machine Learning.

2.9.1. Tipos de modelos de Machine Learning

Existen diferentes tipos de modelo de Machine Learning que se van usando, dependiendo la necesidad, nosotros describiremos algunos de los modelos que consideramos más representativos que podrían aplicarse para la resolución de nuestra propuesta planteada para la empresa Texrell.

a) Regresión Lineal:

El modelo de regresión lineal de acuerdo con Draper y Smith (1998), la regresión lineal es una técnica que permite "estimar la relación funcional entre variables observadas, mediante una forma lineal en parámetros desconocidos" es decir que nos permite predecir una variable continua a partir de otras variables. Tenemos regresión lineal simple y múltiple. La regresión lineal simple es cuando nuestra variable dependiente es explicada solamente por una variable independiente mientras que la regresión lineal múltiple es cuando el modelo es explicado por dos o más variables independientes.

b) Regresión Logística:

A diferencia de la regresión lineal el modelo de regresión logística se utiliza especialmente cuando se tienen variable dicotómicas, por lo tanto, la regresión logística consiste en obtener una función logística de las variables independientes que permita clasificar a los individuos en una de las dos subpoblaciones o grupos establecidos por los dos valores de la variable dependiente ya sea 0 o 1. Los modelos logísticos pueden ser binomiales (que solo puede tomar dos modalidades), multinomiales (que puede tomar más de dos modalidades diferentes, exhaustivas y mutuamente excluyentes), modelos ordenados (con varias modalidades que presentan entre ellas un orden natural) y modelos anidados (que corresponde a una decisión que puede suponer decisiones encadenadas).

c) Árboles de decisión

Barrientos Martínez et al. (2006) explican que los árboles de decisión se construyen a partir de la descripción narrativa de un problema, ya que provee una visión gráfica de la toma de decisión, especificando las variables que son evaluadas, las acciones que deben ser tomadas y el orden en el que la toma de decisión será efectuada. Cada vez que se ejecuta este tipo de modelo, sólo un camino será seguido dependiendo del valor actual de la variable evaluada. Los valores que pueden tomar las variables para este tipo de modelos pueden ser discretos o continuos.

Un árbol gráficamente se representa por un conjunto de nodos, hojas y ramas. El nodo principal o raíz es el atributo a partir del cual se inicia el proceso de clasificación; los nodos internos corresponden a cada una de las preguntas acerca del atributo en particular

del problema. Cada posible respuesta a los cuestionamientos se representa mediante un nodo hijo. Las ramas que salen de cada uno de estos nodos se encuentran etiquetadas con los posibles valores del atributo. Los nodos finales o nodos hoja corresponden a una decisión, la cual coincide con una de las variables clase del problema a resolver.

d) Random Forest

Según Breiman, “Random Forest es un clasificador compuesto por una colección de árboles de decisión contruidos con diferentes muestras aleatorias del conjunto de datos y diferentes subconjuntos de variables, lo que lo hace robusto frente al sobreajuste y eficaz ante datos complejos”. Este método consiste en construir un gran número de árboles de decisión durante el entrenamiento y combinar sus resultados: en clasificación, mediante votación mayoritaria (la clase más frecuente), y en regresión, mediante el promedio de las predicciones. Cada árbol se entrena sobre un subconjunto aleatorio del conjunto de entrenamiento, y en cada división del árbol, solo se considera un subconjunto aleatorio de las variables, lo que introduce diversidad entre los árboles y reduce la correlación entre ellos.

e) Redes Neuronales

Según Haykin (2009), una red neuronal artificial es "un sistema adaptativo que cambia su estructura interna en función de la información que fluye a través de la red durante la fase de aprendizaje". Este aprendizaje se realiza ajustando los pesos sinápticos para minimizar el error entre la predicción del modelo y los valores reales.

Las redes neuronales artificiales están compuestas de gran cantidad de procesadores conectados entre sí y actuando en paralelo y su comportamiento está determinado por su topología, los pesos de las conexiones y la función característica de las neuronas. Las redes neuronales entre las características que tiene es que es de aprendizaje adaptativo, su operación es en tiempo real, es tolerante a fallos parciales y que tiene autoorganización.

2.9.2. Análisis Exploratorio de Datos (EDA)

El análisis exploratorio de datos nos permitirá conocer, organizar, clasificar y correlacionar nuestros datos, para así con la información de estos poder analizarlos y

desarrollar modelos que nos permitan lograr nuestro objetivo planteado. La buena limpieza de datos es fundamental para tener un buen modelo, por lo cual tener un buen EDA será imprescindible para este trabajo.

Según Kelleher (2015) el EDA lo define como que “no es simplemente una tarea preliminar, sino un proceso iterativo y creativo que guía tanto la selección de modelos como la interpretación de los resultados”. Actualmente podemos ver que el EDA va combinando entre análisis estadístico y análisis visual que nos permitirá generar nuestras hipótesis, ver supuestos y preparar los datos para nuestro modelado.

El proceso para hacer un buen EDA consiste en cargar las bases de datos que van a ser utilizadas, para luego limpiarlas y tratarlas, asegurando una buena calidad de los datos y logrando que la información más importante tenga el formato adecuado. Posterior a ese paso, se utilizan estadísticas descriptivas y visualizaciones gráficas para entender la distribución de los datos, los patrones, tendencias y correlaciones entre las variables. Finalmente, se extraen conclusiones a partir del proceso de análisis de datos.

3. Metodología

3.1. Objetivos e Hipótesis

3.1.1. Objetivos

Texrell al ser una empresa líder en su mercado, cuenta con un entorno operativo altamente dinámico que requiere tomar decisiones basada en datos, por lo cual el objetivo principal de este trabajo es poder generar insights que contribuyan a mejorar la planificación operativa, optimizar la rentabilidad de sus contratos y fundamentar la toma de decisiones estratégicas. Para poder llevar a cabo este desafío, se aplicarán técnicas de analítica descriptiva y predictiva, integrando herramientas de estadística, modelado y visualización.

En la fase de analítica descriptiva se realizará un análisis exploratorio de datos (EDA), enfocado en comprender la estructura y comportamiento de las variables, detectar los patrones relevantes, conocer la calidad de nuestros datos y la consistencia de estos. Esta fase se complementará con la construcción de un dashboard interactivo mediante Power Bi que nos ayudará a visualizar nuestros datos de manera más clara, generando insights visuales para la toma de decisiones, ya que como objetivo de esta fase es poder identificar oportunidades de mejora basándose en los datos históricos que tiene la empresa.

En cuanto a la fase de analítica predictiva se desarrollará un modelo de Random Forest, dicha herramienta nos permitirá predecir el margen de rentabilidad estimado de nuestras operaciones, considerando múltiples variables. A partir de estas predicciones podremos anticipar resultados operativos y generar recomendaciones de estos.

Finalmente, a través de este enfoque metodológico, lograremos brindar soluciones analíticas prácticas y orientadas a resultados, que respondan de manera eficiente las necesidades reales detectadas en Texrell.

3.1.2. Hipótesis

Se espera que, a través del análisis de datos operativos y económicos, poder identificar directrices del comportamiento de los contratos que contribuyan a optimizar tanto la rentabilidad como la asignación de recursos de la empresa Texrell.

Igualmente se estima que la aplicación de un modelo predictivo (Random Forest) permita conocer la rentabilidad futura de nuestras operaciones. Finalmente se espera generar insights visuales a partir del uso de herramientas de análisis exploratorio y visualización de datos, que nos ayuden a interpretar los resultados y mejorar la toma de decisiones. Por lo anteriormente mencionado se definen las siguientes hipótesis:

H1: El análisis económico y operativo permite identificar patrones del comportamiento de los contratos que ayuden a mejorar la rentabilidad de la empresa Texrell.

H2: El modelo de predicción Random Forest permite predecir el margen estimado de los contratos futuros de la empresa.

H3: El dashboard elaborado permite generar insights efectivos para la toma de decisiones de Texrell.

3.2. Descripción de los datos

3.2.1. Delimitación de factores:

Durante nuestro análisis utilizaremos un análisis cuantitativo. Este es 'el enfoque científico de la toma de decisiones administrativas.' (Render, Stair & Hanna, 2012, p.2) este análisis se basa en los datos de la compañía los cuales se manipulan o se procesan para convertirlos en información para la toma de decisiones. Este proceso de la manipulación y procesamiento de los datos convertidos en información significativa son la esencia del análisis cuantitativo.

Además del análisis cuantitativo, es fundamental considerar los factores cualitativos, que son elementos no cuantificables de una compañía, como los productos, maquinarias, servicios y otros aspectos intangibles, los cuales pueden generar variaciones significativas en el proceso de toma de decisiones.

3.2.2. Delimitación de problema:

El primer paso en el enfoque cuantitativo es delimitar un enunciado claro y conciso acerca del problema ya que este dará la dirección y significado a los siguientes pasos.

En este caso la compañía TEXRELL enfrenta desafíos significativos en la gestión y planificación de sus recursos, así como en la rentabilidad de los contratos que mantiene activos. La falta de un sistema analítico robusto para evaluar el desempeño de sus

operaciones, sumado a la complejidad de gestionar múltiples contratos de servicio en un entorno de alta volatilidad, ha generado dificultades para optimizar el uso de sus recursos y maximizar los beneficios operativos.

3.2.3. Delimitación de datos a utilizar:

Para resolver esta problemática, de acuerdo con el análisis realizado se obtuvo diferentes periodos de tiempo para poder analizar diferentes etapas que tuvo la empresa, primeramente, se utilizan los datos recopilados por la empresa de cuatro gestiones desde el primero de enero del 2021 hasta el 31 de diciembre del 2024 para la realización del Power Bi relacionado a la rentabilidad, duración de contratos y contratos deficitarios. Complementando el análisis de visualización para el sector de las llamadas de servicio se utilizo las gestiones de mayo 2024 a mayo 2025 para dar énfasis en el periodo más actual de la distribución de sus servicios y unidades de negocio que tuvo Texrell.

Posteriormente, para realizar el modelo de Random Forest se utilizan el periodo abarcado desde el 01 de enero de 2023 hasta el 31 de diciembre del 2024.

Esta información histórica ha sido registrada en los sistemas CRM y ERP de la compañía, siendo este último el sistema SAP. Los datos serán extraídos en hojas de Excel para su posterior análisis.

En dicha hoja de datos se incluirá la siguiente información:

- *Clientes*: contiene los nombres de los clientes que solicitan los servicios de la compañía.
- *Regiones*: muestra las zonas geográficas donde se prestaron los servicios.
- *Tipos de grúas*: indica los diferentes tipos de maquinarias utilizados para desarrollar las actividades solicitadas.
- *Cantidades de grúas*: especifica el número de unidades empleadas en cada operación.
- *Duraciones de operación*: detalla la cantidad de días requeridos para completar cada actividad.
- *Costo de operación*: presenta los gastos operativos incurridos por la empresa en el desarrollo de la actividad.

- *Importe de operación*: refleja el monto facturado al cliente por la ejecución del servicio.

3.3. Tratamiento de los datos

3.3.1. Definición de la metodología de tratamiento de datos:

La metodología de tratamiento de datos se refiere al conjunto de procedimientos y técnicas utilizadas para recopilar, organizar, procesar y analizar datos con el fin de convertirlos en información útil para la toma de decisiones. Este proceso incluye etapas como la codificación, el registro, la evaluación y la interpretación de los datos.

Según Sánchez Estella y Herrero Domingo (2021), el tratamiento informático de datos abarca la introducción de datos utilizando técnicas mecanográficas hasta el uso de aplicaciones ofimáticas como procesadores de texto, hojas de cálculo y bases de datos para gestionar y analizar la información de manera eficiente.

3.3.2. Metodología empleada para el tratamiento de datos:

A continuación, se describe los pasos que conforman la metodología utilizada para el tratamiento de datos obtenidos desde el sistema SAP, con el fin de analizarlos y desarrollar un modelo predictivo:

- Exportación de datos desde SAP

descripción: Se extrae la información desde SAP en formato CSV.

Objetivo: Obtener una base de datos estructurada que nos sirva para el análisis.

- Importación de base de datos

descripción: Se importará el archivo CSV a VSCode.

objetivo: Manipulación de datos de gran volumen con las herramientas aportadas de librerías y lenguaje de programación Python.

a) Limpieza y transformación de datos

Librería utilizada: pandas

Tareas realizadas:

- Eliminación de valores nulos o duplicados.
- Conservación de tipos de datos.

- Eliminación de columnas irrelevantes.
- Filtrado de registros irrelevantes.

b) Análisis estadístico

Librería utilizada: numpy

Objetivo: Calcular medidas descriptivas como: Media, Mediana, Desviación estándar, Percentiles, Análisis de correlaciones, Análisis de dispersión, Identificación de valores atípicos.

c) Visualización de datos

Librerías utilizadas: matplotlib y seaborn

Objetivo: Detectar patrones, anomalías y relaciones entre variables mediante gráficos como: Histogramas, Diagramas de dispersión, mapas de calor, gráficos de barras y líneas.

d) Implementación del modelo predictivo

Librería utilizada: scikit-learn

Modelo: RandomForestRegressor

Pasos:

- División del conjunto de datos en entrenamiento y prueba.
- Entrenamiento del modelo
- Evaluación del modelo con métricas que serán RMSE y R^2

3.4. Modelado y técnicas

De acuerdo con los objetivos establecidos, el modelo de predicción que será desarrollado tendrá como principal finalidad evaluar la rentabilidad estimada de cada contrato futuro, usando como criterio los patrones encontrados a partir de datos seleccionados. Este modelo permitirá encontrar los contratos más rentables para la empresa y también identificar la unidad de negocio con mayor rendimiento financiero.

Este modelo de predicción será desarrollado a partir de los siguientes datos:

- Cliente

- PCIA (Región)
- Descripción del equipamiento
- Cantidad de días
- Coste
- Importe

Los datos utilizados para este trabajo son originales del dataset llamado Anging Texrell. A partir de esta base de datos, fue realizada un EDA (análisis exploratorio de datos) con el objetivo de comprender la estructura de los datos y un tratamiento de datos para dejar los datos dentro de los patrones aceptables para realización del modelo de predicción. Todo el proceso está siendo procesado en un entorno Python, a partir de Jupyter Notebook justamente para facilitar la manipulación y visualización de datos a cada etapa.

El modelo de predicción que parece mejor ajustarse a nuestra necesidad de predicción es el modelo Random Forest Regressor, justamente por ser capaz de identificar patrones complejos a partir de variables numéricas y también categóricas. Para eso, serán utilizadas todas las columnas filtradas que hemos comentado arriba.

Además, será utilizada la técnica de cross-validation para evaluar la robustez y validación del modelo.

Para realizar el modelo se dividió al conjunto de datos en dos subconjuntos, un 80% como datos de entrenamiento y un 20% como datos de testeo, usando una división aleatoria de los mismos. También se empleó lo mencionado un cross-validation con 5 particiones para de esa manera evitar el sobreajuste del modelo.

3.5. Evaluación del modelo

Para la evaluación de nuestro modelo de predicción, utilizaremos tres principales técnicas: MSE (Mean Square Error), RMSE (Root Mean Squared Error) y R^2 (R-squared).

El MSE mide el promedio de los errores al cuadrado de las predicciones y los valores reales. Su principal objetivo es evaluar la calidad de la predicción. Mientras más bajo sea el error, mejor es el ajuste del modelo.

Similar al MSE, el RMSE mide el promedio de los errores al cuadrado de las predicciones y los valores reales, pero la principal diferencia de esta métrica es que utiliza las mismas unidades de la variable que estamos prediciendo. El resultado del RMSE significa la

variación real de los datos. Ejemplo: un RMSE de 2 significa que el promedio de las predicciones desvía 2 puntos porcentuales del margen real.

Ya el R^2 nos da como resultado el porcentaje de los datos reales que el modelo logra explicar. Su resultado varía entre 1 (resultado perfecto) hasta resultados negativos. Los valores cercanos a 1 significan que el modelo explica bien la variación de los datos. Los valores cercanos a 0 significan que el modelo no explica casi nada, se podría usar la media para predecir los resultados. Ya los valores negativos significan que el modelo está peor que la media y posiblemente sesgado.

3.6. Herramientas utilizadas

Para el desarrollo de este trabajo se utilizaron diferentes tipos de herramientas, a continuación, se detallan las herramientas utilizadas:

3.6.1. Python

Se decidió utilizar el lenguaje de programación Python por su amplia versatilidad en el mundo de análisis de datos y además que es una herramienta que cuenta con una gran variedad de librerías especializadas. Utilizamos esta herramienta para realizar el análisis exploratorio de datos (EDA) y el modelo predictivo Random Forest. Para este proyecto, hemos utilizado las librerías de Pandas para tratamiento de datos, numpy para cálculos matemáticos, seaborn y matplotlib.pyplot para visualización de resultados y datetime para trabajar con fechas.

3.6.2. Visual Studio Code

Hemos utilizado el IDE (Entorno de Desarrollo Integrado) de Visual Studio Code, debido a su interfaz dinámica y fácil de utilizar, integración con las principales librerías de Python de forma nativa y su soporte para utilizar otras herramientas de ejecución y extensiones que nos ayudan a optimizar el proyecto. Dentro del Visual Studio Code desarrollamos los códigos de Python utilizando Jupyter Notebook, pues de esa manera logramos combinar el código, con los resultados y visualizaciones realizadas.

3.6.3. Google Docs

Esta herramienta Google Docs fue fundamental para el desarrollo del documento final, nos permitió realizar las redacciones correspondientes, elaborar los objetivos, las metodologías utilizadas y sobre todo para poder presentar los resultados del trabajo, se decidió utilizar esta aplicación debido a que es una herramienta que nos permite trabajar de manera colaborativa en línea, lo que facilitó el trabajo en equipo para los integrantes del grupo.

3.6.4. Google Sheets

Se utilizó esta herramienta como parte de la etapa inicial, debido a que los datos proporcionados de la empresa Texrell llegaban en este formato, Google sheets al ser una hoja de cálculo en línea nos permitió realizar una primera visualización de los datos antes de su procesamiento en Python.

3.6.5. Power Bi

Power Bi es la herramienta visual que decidimos emplear para la fase de creación de dashboards y toda visualización interactiva de los datos, esta herramienta destaca por tener una gran potencia visual en gráficos, tablas, mapas, filtros, esquemas, entre otros. Por lo que mediante esta herramienta nos ayudó a generar los insights relevantes y además nos ayudó a complementar las fases previas realizadas en Python. Además, otro motivo por el cual optamos el uso de esta herramienta es debido a que la misma ya empezó a ser introducida en el sistema operativo de la empresa.

3.6.6. SAP

SAP es el sistema ERP que utiliza la empresa para el registro y gestión de sus datos, por lo cual para nosotros SAP fue la fuente de origen de los datos, aportando toda la información sobre los procesos, costos, ingresos que tiene la empresa, y de la cual se basó todo el trabajo presente.

3.7. Participantes

Durante el desarrollo del presente trabajo se asumieron distintos roles que fueron distribuidos entre los cuatro miembros conformantes del equipo, los cuales se distribuyeron de la siguiente manera:

3.7.1. Responsable de coordinación

Como responsable de coordinación se encuentra Jorgelina Antonarakis, persona encargada de la coordinación general del proyecto, pero especialmente es la persona encargada de mantener la comunicación directa con la empresa. Fue quien gestionó y obtuvo la información necesaria para llevar a cabo este proyecto, asegurando la viabilidad de este.

3.7.2. Analista de datos

Como analista de datos se encuentra Daniel Simon, responsable de la limpieza y estructuración de los datos, desarrolló el análisis exploratorio de los datos (EDA) en colaboración con Cristian Patzlaff, quienes conjuntamente trabajaron en la etapa previa del modelado, garantizando la calidad y pureza de los datos.

3.7.3. Científico de datos

Como científico de datos está Cristian Patzlaff, encargado de desarrollar el modelo predictivo Random Forest, el ajuste de los parámetros y la evaluación del mejor modelo. Logrando así aportar de manera técnica y analítica al proyecto. Cabe destacar que en el desarrollo del modelo también colaboró Daniel Simon.

3.7.4. Analista visual de datos

Como Analista visual de datos está Fernanda Romero en conjunto con Jorgelina Antonarakis, se encargaron de la creación de las visualizaciones e insights mediante la herramienta de Power Bi, permitiendo interpretar los resultados del proyecto de una manera visual e iterativa.

4. Resultados

A continuación, se presentará los resultados obtenidos de la realización del modelo de predicción para predecir la rentabilidad de los contratos, de igual manera se enseñará los insights obtenidos de la elaboración del Dashboard que ayuda a evaluar la rentabilidad de los contratos, identificar aquellos con bajo margen, segmentar los clientes más rentables, y evaluar la rentabilidad de los contratos según su tiempo de duración.

4.1. Modelo de Predicción Random Forest

El principal objetivo de este modelo es predecir el margen de los contratos futuros de la empresa, basado en datos históricos, y de acuerdo con variables como provincia, maquinaria, la cantidad de días de contrato y el precio.

Primero, hemos filtrado las columnas más importantes: 'Periodo', 'CLIENTE', 'PCIA', 'ITEM_DESC', 'CANTIDAD_DIAS', 'PRECIO', 'IMPORTE'. Después eliminamos los registros con valores 0, para trabajar solamente con datos válidos y también filtramos por periodo de enero de 2021 a diciembre de 2024.

Para simplificar y poder trabajar mejor con los datos, como las columnas de PRECIO e IMPORTE del dataset estaban en pesos argentinos (ARS), las convertimos a euros, dividiendo por 1300 (cotización de referencia) y también generalizamos las máquinas de la empresa en estas categorías: GRUA, MANLIFT, CARRETÓN, PALA, SEMIRREMOLQUE, TRAILER y CAMION.

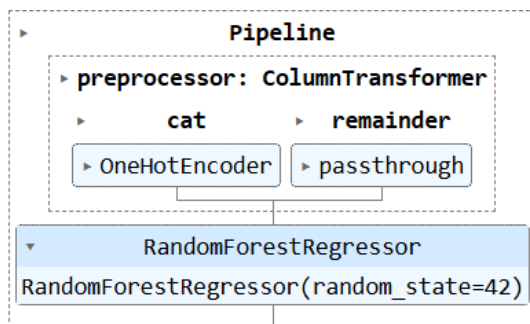
Con las columnas ya en euros, creamos una columna llamada de COSTE_TOTAL, usando rangos de margen para cada tipo de máquina. Los siguientes rangos de margen, GRUA (40% a 60%), MANLIFT (35% a 50%), CARRETON (45% a 60%), PALA (30% a 45%), SEMIRREMOLQUE (40% a 55%), TRAILER (35% a 50%) y CAMION (50% a 65%), fueron definidos de forma aleatoria por una función a partir de la librería numpy en Python.

A partir de la columna COSTE_TOTAL, creamos otra columna llamada MARGEN, que se calcula como la diferencia entre el IMPORTE y el COSTE_TOTAL, dividida por el IMPORTE. Es decir, representa el porcentaje de ganancia sobre el valor facturado.

Para entrenamiento del modelo, utilizamos las variables de 'CLIENTE', 'PCIA', 'ITEM_DESC', 'CANTIDAD_DIAS', 'IMPORTE', y como variable objetivo el MARGEN. Como trabajamos con variables categóricas, se hizo necesaria la transformación de las variables 'CLIENTE', 'PCIA', 'ITEM_DESC' con OneHotEncoder, una función que permite que el modelo entienda los patrones de palabras y que haga relación con demás variables. Para entrenamiento, divididos los datos en 80% train y 20% para test.

Entrenamos un modelo de RandomForestRegressor con validación cruzada (KFold, n=5).

Ilustración 3: Modelo de predicción



Fuente: Elaboración propia.

Para probar el modelo, utilizamos un ejemplo de contrato con un cliente específico, una provincia determinada, el tipo de máquina, la cantidad de días de alquiler y el importe total. Con esa información, el modelo nos devuelve una estimación del margen. Por ejemplo, al ingresar los datos, el modelo puede predecir que el margen estimado para ese contrato sea del 50,18%, y esto nos permite anticipar si el contrato es rentable o no antes de firmarlo, y tomar decisiones más estratégicas basadas en datos.

Los resultados del entrenamiento con validación cruzada fueron de MSE: 0.0033, un de RMSE: 0.0574 y R^2 : 0.2697. Ya en el set de test tuvimos resultados similares, de MSE: 0.0033, RMSE: 0.0577 y R^2 : 0.2705, y eso nos dice que el modelo no está con overfitting. Los resultados no son tan altos porque los datos usados son simulados y simplificados, no son 100% reales. Pero la lógica del modelo funciona, y si se entrena con datos verdaderos de la empresa, es muy probable que el rendimiento mejore bastante y sea más preciso. Tal como está, no es recomendable usar el modelo en producción, es decir, no debería tomarse como una base confiable para decisiones reales.

4.2. Dashboard

Se elaboro un informe visual en Power Bi que me permitió generar insights positivos que van resolviendo los objetivos planteados anteriormente en el presente trabajo, de esa manera lograr generar valor a la información proporcionada por la empresa y generar de manera visual una ayuda para la toma de decisiones.

4.2.1. Evaluación Financiera

Este panel está diseñado para ofrecer una visión general financiera de los contratos realizados por la empresa desde 2021 hasta el 2024. Se centra en métricas claves como los ingresos totales, los costes totales y los márgenes de beneficio. Aparte de estas métricas se realizaron múltiples gráficos, tablas y mapa con los cuales se busca generar un desglose más detallado, estas son:

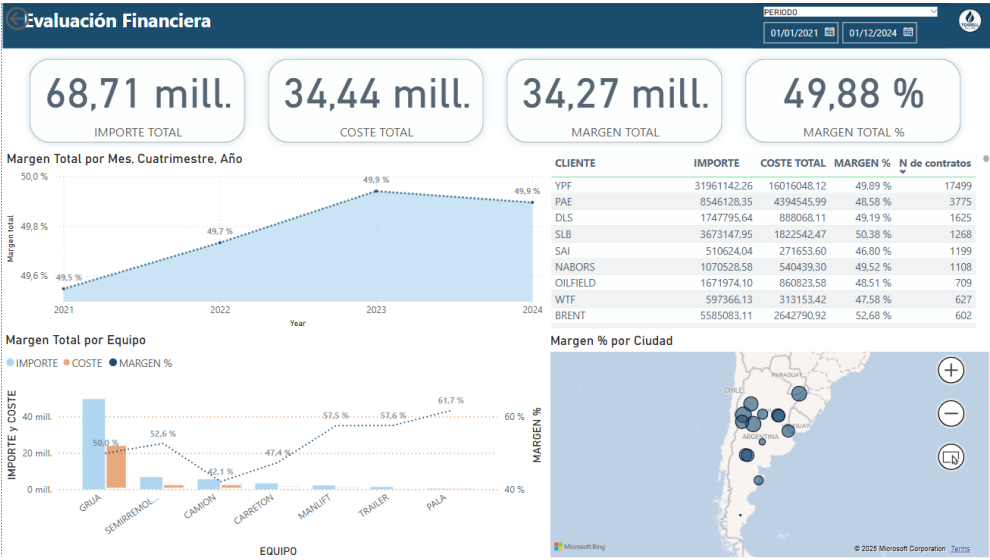
Gráfico de líneas, (llamado 'Margen Total por Mes. Cuatrimestre. Año') que visualiza el porcentaje de margen de beneficio a lo largo de los diferentes meses del año. En este se puede observar fluctuaciones en el porcentaje de margen, con picos y valles a lo largo del año.

Tabla de cliente, En esta tabla se proporciona un desglose detallado del rendimiento financiero por cliente individual. Para cada cliente muestra, importe que son los ingresos totales generados a partir de contratos con ese cliente específico. Coste total lo cual es el costo total asociado a las actividades realizadas para ese cliente. Margen % que es el porcentaje de margen de ganancia logrado con cada cliente.

Mapa de margen por ciudad, esta es una representación geográfica que muestra las ciudades donde la empresa ha realizado trabajos. En este se utiliza burbujas para indicar el margen de beneficio obtenido en cada ciudad. Estas burbujas obtienen su tamaño proporcional al margen generado.

Gráfico de margen total por equipo, este grafico combina gráficos de barras y líneas para ilustrar el rendimiento financiero asociado a los diferentes tipos de equipos utilizados en las actividades de la empresa. Este permite analizar que tipos de equipos son más rentables.

Ilustración 4: Visualización de Rentabilidad por Contrato, por Equipo y por Provincia.



Fuente: Elaboración propia

4.2.2. Contratos Deficitarios

Este panel está diseñado para identificar, cuantificar y analizar los tratos que no han sido rentable o que han tenido un margen bajo. Se centra en métricas claves como los montos totales de perdida por contratos, número de contratos con perdida, monto total generado por los contratos con bajo margen, número de contratos con bajo margen.


Ilustración 5: Visualización de Estado de Rentabilidad de los Contratos



Fuente: Elaboración propia

Para detectar los contratos deficitarios se clasifico para la variable margen de acuerdo con sus resultados en tres inputs, “OK” cuando el margen es superior o igual al 45%, “Margen Bajo” mayor o igual al 40% y menor al 45%, “Pérdida” menor al 40%, esta clasificación se hizo en conjunto de las metas que tiene la empresa. Este gráfico de líneas con doble eje muestra la evolución temporal del número de contratos con “margen bajo” y “contratos en pérdidas” desde el 2021 hasta el 2024. La línea azul (Número de contratos en margen bajo), La línea naranja (Contratos en perdida). A partir de aquí se pudo ver que desde la gestión 2021 a la gestión 2024 la mayoría de nuestros contratos se encuentran en OK representando el 75.48% (26384), un 20.23% Margen Bajo (7071), y finalmente en estado perdida un 4.29% (1500). Pasando estos datos en una cifra monetaria durante el rango de estas gestiones se encuentran contratos en estado Perdida que generan 781.68 mil euros, y en estado margen bajo 6.49 millones de euros.

Ilustración 6: Evolución en el tiempo del estado de los contratos




Fuente: Elaboración propia

En la Ilustración 7, este grafico desglosa el número de contratos con margen bajo y contratos en pérdidas por tipo de equipo. Aquí podemos observar que los contratos tienen dos grandes picos, primero el de contratos con margen bajo presenta un pico de grande levantamiento en la gestión 2022 teniendo una tasa de incremento de 19.71%, en cuanto a contratos en perdida se puede ver que durante las primeras tres gestiones se mantiene estable, pero en la gestión 2024 presenta un pico de incremento de 35.38%.

Además, un patrón que se logro encontrar es que durante las cuatro gestiones los equipos que se encuentran en perdida y bajo margen son los contratos de equipos de grúa, camión y carretón.


Ilustración 7: Tipo de contratos por Equipo



Fuente: Elaboración propia

Finalmente se hizo la misma subdivisión de tipo de contratos por provincia y por cliente, donde Neuquén es la zona con el mayor tipo de contratos deficitarios, pero tiene mucha relación ya que es la zona donde se encuentran un 91.25% de los contratos que genera la empresa.

Ilustración 8: Contratos deficitarios por provincia




Fuente: Elaboración propia

Similar al gráfico anterior, esta muestra el número de contratos con margen bajo y en pérdida por cliente. YPF es el cliente con mayores contratos deficitarios, pero a su misma manera es el cliente más grande de la empresa que maneja un 51% de los contratos,

sugiriendo que la relación con este cliente podría necesitar una revisión en términos de rentabilidad.

Ilustración 9: Contratos deficitarios por cliente

Número de Contratos Deficitarios por Cliente



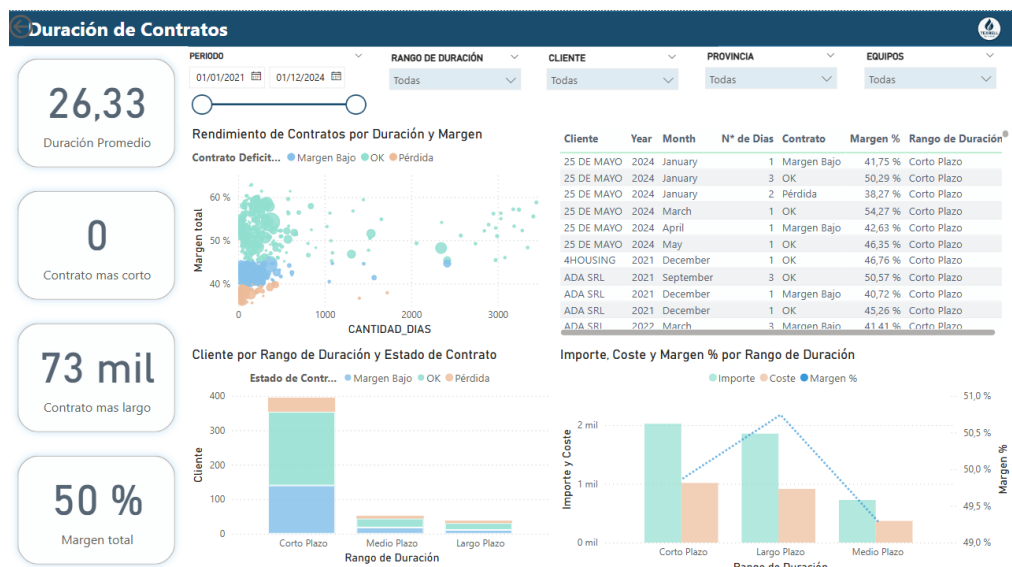
Fuente: Elaboración propia

4.2.3. Duración de Contratos

Este panel está diseñado para analizar la relación entre la duración de los contratos y su rendimiento, especialmente en términos de margen de ganancia. Se centra en métricas claves como la duración promedio de todos los contratos analizados, el margen de ganancia promedio de todos los contratos en el periodo seleccionado, duración de los contratos con más y menos plazos. Aparte de estas métricas presentamos gráficos para delimitar temporalidades de estos contratos.

Con las visualizaciones realizadas como datos de información se pudo ver que el contrato mas rápido puede tener una duración de cero días y que actualmente el contrato más largo que se tiene es de 72576 días en Neuquén con el equipo carretón, también se pudo determinar que el promedio de duración de los contratos es 26.33 días, pero aquí se logró identificar outliers.


Ilustración 10: Duración de Contratos



Fuente: Elaboración propia

Se realizo un gráfico de dispersión el cual nos permitió conocer por cantidad de duración de días de los contratos cómo evoluciona su margen obtenido, donde se puede ver que la duración del tiempo de contrato no tiene una relación directa con que, si es rentable o no, ya que los datos se centran en el rango de 0 a 500, algo a destacar fue que a medida que iban creciendo los contratos es decir los contratos de larga duración tienden a estar con mejor margen presentado un estado OK. Ver Ilustración 11.


Ilustración 11: Rendimiento de contratos por duración



Fuente: Elaboración propia

Posteriormente se realizó una clasificación a la variable de cantidad de días en tres inputs corto plazo es igual o menor a 60 días, mediano plazo es mayor a 60 días y menor o igual a 180 días y largo plazo que es mayor a 180 días. Obteniendo así que los contratos se centran en una duración corto plazo y que más del 50% de los contratos a corto plazo tienen un margen en estado OK.


Ilustración 12: *Cliente por rango de duración y estado de contrato*



Fuente: Elaboración propia

También se realizo un grafico de barras que nos permitió ver que contratos son los que tenían mayor importe y coste, y cual generaba mayor margen de ganancia. Aquí se pudo observar que los contratos a corto y largo plazo son los que presentan mayor importe, pero que el margen de ganancia promedio en largo plazo (50.74%) es mejor que el de corto plazo (49.88%).


Ilustración 13: *Importe, coste y margen % por rango de duración*



Fuente: Elaboración propia

4.2.4. Llamadas de servicio

Ilustración 14: Distribución anual de Llamadas de Servicios en Base a clientes y Unidades de Negocio



Fuente: Elaboración propia

El análisis inicial sobre las llamadas de Servicio sobre Unidades de Negocio y Clientes es:

1. Volumen general de operaciones

Resultado: Actividades registradas: 78.000, Llamadas únicas: 3.823

Discusión: Cada llamada deriva, en promedio, en algo más de cuatro actividades. Se tuvo en cuenta la distinción de llamadas y actividades ya que no son un ID único, sino que se repiten. Esto aporta un valor positivo de análisis de detalle de las operaciones y costos, aunque supone un esfuerzo administrativo considerable. Revisando los registros pueden automatizarse o agruparse para aligerar la carga diaria.

2. Clientes con mayor demanda

Resultado: Los cinco clientes que más requieren los servicios son YPF, Pan American Energy, Nabors, San Antonio y DLS Acher.

YPF encabeza la lista en 2024 y 2025.

Discusión: esta concentración indica dependencia operativa sobre grandes clientes, habla de mantener en el tiempo la excelencia del servicio, pero se debería abrir un abanico más grande a otras operadoras.

3. Subunidades de Negocio más utilizadas

Resultado: En 2025 destacan GRU 01 (grúas), TCS-03 (Camiones), ALQ-03 (tráileres), GRU-02 (Manlift) y ADM-05 (Personal administrativo), destacamos que la administración de personal y recursos humanos no pertenecen a subunidades que incrementen la facturación.

Discusión: Estas áreas concentran la mayor parte de las solicitudes. Conviene verificar si este uso intenso se traduce en una buena rentabilidad o si solo responde a disponibilidad de recursos. Indicadores como horas operativas por equipo o costo por hora ayudarán a aclarar el panorama y detectar posibles ineficiencias.

4. Unidades de negocio con mayor carga

Resultado: UN-GRU es la unidad de negocio líder por excelencia en 2025, seguida de UN-TCS (Transportes de cargas sólidas), UN-ALQ (tráileres), UN DTM (desmontaje, transporte y montaje), y ADM (administración). Siendo ésta última la unidad que representa tareas administrativas no facturables. Podemos observar que la Unidad de Negocio que mayor requerimiento tiene es la de Grúas que incluye subunidades como grúas, manlift y auto elevadores, recursos de gran valor en la operación petrolera.

Discusión: Un indicador claro es que la Unidad de grúas es quien merece la atención y prioridad en el mantenimiento de recursos, debería incrementar su flota e invertir aún más en grúas eléctricas como producto innovador y competente en el mercado petrolero. Por otro lado, se observa que los Servicios Viales (SSV) no están en su máxima potencia de prestación debería reverse con el equipo de cotizaciones para ofrecer en los servicios.

5. Tipo de llamadas – Externas vs. Internas

Resultado: El 96,39 % de las llamadas, provienen de clientes externos y un 3.61% pertenece al cliente interno que es Texrell.

Discusión: Un indicador claramente positivo: casi toda la energía del equipo se dedica a tareas facturables. El restante pertenece a actividades internas, logrando así un alto retorno de ganancias.

Entre las Recomendaciones Claves planteamos:

- Diversificar la cartera: sumar nuevos clientes y equilibrar el peso de los actuales.
- Medir la rentabilidad por subunidad: especial atención a la unidad de grúas y transportes de cargas sólidas, para que su uso intensivo genere márgenes saludables.
- Centrarse en recuperar las Unidades que han bajado su rendimiento como SSV y DTM, evaluar su prestación y tiempos de servicio.
- Revisar las áreas poco activas: detectar si sobran recursos o si hace falta redefinir su propósito.
- Vincular métricas comerciales y operativas: incorporar indicadores de facturación o ganancia por cliente y por unidad para tomar mejores decisiones.

5. Validación de Hipótesis

5.1. H1: El análisis económico y operativo permite identificar patrones del comportamiento de los contratos que ayuden a mejorar la rentabilidad de la empresa Texrell.

De acuerdo con la hipótesis H1, donde se esperaba que mediante el análisis económico y operativo se identifiquen patrones que nos permitan entender el comportamiento de los contratos para la mejora de su rentabilidad de estos, los resultados obtenidos muestran que el estado de nuestros contratos un 75.78% se encuentran con un margen superior al 45% estando en un estado OK de margen, que durante estos últimos cuatro años se vio un incremento en el margen promedio anual de la compañía durante la gestión 2023 elevando a su pico más alto y en la gestión 2024 presentando una pequeña disminución pero manteniéndose casi estable, se logró identificar que la zona que genera mayor ingresos a la empresa es Neuquén, nuestros clientes que presentan mayor rentabilidad es Leimat (63.13%), Coantra (59.70%) y Confluencia (59.72%), pero en cuanto generación de ingresos la empresa que tiene mayor número de contratos y mayo importe aporta a la compañía es YPF con 17499 contratos y un importe de más de 31 millones de euros durante las ultimas gestiones. También se pudo ver la demanda de contratos por equipo donde grúa, camión y carretón son los equipos que presentan márgenes con contratos bajo o contratos en pérdida.

Finalmente, estos hallazgos nos permiten confirmar nuestra hipótesis que el análisis realizado permitió identificar patrones del comportamiento de los contratos relacionados a su rentabilidad, y a partir de esta información aportar directrices para la toma de decisiones. Cabe destacar que la rentabilidad de los contratos también pueda estar influenciada por otros parámetros no considerados como condiciones externas a la empresa, entre otras.

5.2. H2: El modelo de predicción Random Forest permite predecir el margen estimado de los contratos futuros de la empresa.

La hipótesis H2 sobre la realización de un modelo predictivo Random Forest que nos permita predecir el margen de futuros contratos basándose en datos históricos de la compañía.

Una vez realizado el modelo fue entrenado con las variables mencionada en resultados utilizando tanto variables numéricas como categóricas, con un 80% de entrenamiento y 20% de testeo, obteniendo un MSE de 0.0033, RMSE de 0.0574 y un R2 de 0.2697 en entrenamiento, obteniendo valores muy similares a la hora de entrenar con los datos de testeo, demostrando que no existe overfitting. Cabe destacar que de acuerdo con el R2 obtenido el modelo tiene una baja capacidad explicativa, pero eso se debe a que el modelo presenta datos simulados y simplificados.

Por lo tanto, la hipótesis H2 no se confirma completamente, ya que el modelo tiene la capacidad para estimar los márgenes de contratos, pero con limitaciones debido a la base de datos y protección de datos de la compañía.

5.3. H3: El dashboard elaborado permite generar insights efectivos para la toma de decisiones de Texrell.

En cuanto la hipótesis H3 se plantea la elaboración de un dashboard que permita generar insights que faciliten y contribuyan a la toma de decisiones de la compañía. Se realizó un dashboard integral que comprende múltiples ámbitos relacionados con la rentabilidad por contratos, por cliente, por equipos, evoluciones temporales, duración de los contratos dándonos una perspectiva de la realidad operativa que Texrell está teniendo.

Estas visualizaciones nos permitieron detectar patrones de nuestros contratos, logrando identificar que los contratos se centran en una duración a corto plazo (32.949) representan el 94%, pero que a diferencia de los contratos con mediano (1565) y largo plazo (441) estos dos últimos presentan netamente una rentabilidad positiva, revelando que la duración de los contratos puede influir en la rentabilidad de los mismos, lo cual este análisis nos permitirá guiar en la toma de acciones acerca de la duración futura de los

mismos. A su vez se logro detectar que nuestro cliente que tiene mayor importe a la empresa cuenta con gran representación de nuestros ingresos el cual tiene presente 17499 contratos de los 34955 que cuenta la empresa, siendo este cliente el 50% del movimiento de la empresa, esto puede guiar a la empresa a realizar un análisis específico de este cliente, y tomar estrategias de diversificación para no depender únicamente de este cliente.

Con lo anteriormente mencionado podemos confirmar la Hipótesis 3, ya que el dashboard está proporcionando insights fructíferos para la compañía que contribuyen a la mejora de toma de decisiones de esta, en diferentes ámbitos en relación con sus contratos, clientes, rentabilidad y otros.

6. Conclusiones

El propósito central de este trabajo de fin de Máster consistió en mejorar la gestión contractual y operativa de la empresa Texrell mediante la combinación de analítica descriptiva – articulada a través de tableros interactivos en Power BI y analítica predictiva, representada por un modelo de Random Forest. Los resultados confirman, sobre una base empírica robusta, que esta sinergia aporta beneficios concretos y cuantificables para la compañía. Como conclusión se ha logrado demostrar el gran valor que generan el uso de las herramientas de Business Analytics para la optimización de toma de decisiones.

En primer lugar, el modelo predictivo Random Forest permitió acercarnos a estimar el margen de los contratos futuros de la empresa, aunque los resultados del modelo no reflejaban una capacidad explicativa elevada, pero esto es debido más a la naturaleza del modelo en sí, que a una simplificación excesiva de los datos. Si bien se realizaron transformaciones y la selección de variables en base a criterios de negocio, se comprobó que el modelo permite acceder a las importancias de las variables (se pueden visualizar en **Anexo N**), lo cual aporta claridad sobre qué factores impactan más en el margen. Por ejemplo, se identificó que el importe, la cantidad de días y ciertos ítems específicos explican gran parte del comportamiento del margen, lo cual confirma la validez del enfoque predictivo aplicado y permite no solamente anticipar la rentabilidad de los contratos, sino también abrir la posibilidad de desarrollar otros modelos como ser un modelo que nos permita estimar el mantenimiento de los equipos de trabajo.

En cuanto la elaboración del dashboard en Power Bi se logró transformar los reportes obtenidos de SAP en visualizaciones dinámicas y sencillas que generan insights que permiten contribuir al área gerencial en la toma de decisiones. Resolviendo los objetivos planteados de dicho trabajo. En cuanto al segundo, tercer objetivo y cuarto objetivo, logramos evaluar la rentabilidad de los contratos por cliente, por equipos, por zona, aquí logramos identificar que los contratos con margen bajo o en pérdida juntos representan el 24.5% del total, dicho porcentaje puede representar una oportunidad de mejora para que la empresa disminuya aún más este número. Además, se logró detectar precozmente los contratos con riesgo de pérdida, se alcanzó gracias a la serie temporal incorporada en Power BI. El análisis identificó dos momentos críticos (segundo trimestre de 2022 y

primer trimestre de 2024) en los que el margen cayó más de cinco puntos porcentuales. De haberse detectado estas inflexiones antes del cierre contable, se habría evitado un deterioro cercano a 2,3 millones de dólares, de cara al futuro, la monitorización diaria ayudará a prevenir desviaciones similares.

Otro punto importante por destacar fue que la zona de Neuquén y el cliente YPF concentran la mayoría de los contratos deficitarios, pero estos a su vez son los que generan contratos con mayores importes, comprobando la relación compleja que existe entre la dependencia a este cliente, el volumen y la rentabilidad de estos. Cerrando con que el tiempo de duración de los contratos señala que entre mayor tiempo de duración la rentabilidad se mantiene mejor, ya que en los contratos de menor duración son los que podemos ver que se concentran nuestros contratos deficitarios.

En cuanto al quinto objetivo la distribución anual de llamadas de servicios del último año (05-2024 a 05-2025), arroja un registro de 78 mil actividades registradas y 3823 llamadas únicas que completa la panorámica operativa de la compañía. En 2024 se concentró algo más de la mitad de las solicitudes (52%) con YPF encabezando el ranking con 573 llamadas, seguida por Pan América Energy y Nabors. Al año siguiente, YPF mantuvo el liderazgo con 461 llamadas, y DLS, duplicó su participación y se incorporó al grupo de clientes más demandantes. Desde la perspectiva interna, las Unidades de Negocio de grúas y transportes de cargas sólidas absorbieron cerca del 63% del total de llamadas, lo que revela posibles cuellos de botella y subraya la necesidad de revisar la asignación de recursos. Contar con esta radiografía anual permite anticipar picos de demanda, reforzar las áreas críticas, y poner mucho foco en la unidad de grúas al ser la unidad de mayor demanda para poder analizar futuras inversiones en esta unidad o evitar desabastecimiento de esta. Concluyendo se pudo ver que nuestras llamadas de servicio en casi su totalidad provienen de clientes externos lo cual llamadas internas es un movimiento no significativo para Texrell.

Con lo anteriormente mencionado podemos confirmar que se ha logrado alcanzar los objetivos planteados en el trabajo, ofreciendo una mejora analítica a la empresa, ofreciendo paneles visuales que fomentan a una cultura orientada en datos.

Además, recomendamos que Texrell ponga en funcionamiento, cuanto antes, los paneles de Power BI y el modelo Random Forest desarrollado en el trabajo. Ambos ofrecen una

guía recomendable para elevar la rentabilidad: permiten localizar de inmediato el reducido grupo de contratos que hoy generan pérdidas y renegociarlos antes de que provoque una fuga importante de costos, a la vez que filtran las nuevas licitaciones con un riesgo elevado de pérdidas. Para sacarle el máximo partido bastará con crear un equipo mixto puede ser entre Finanzas, Operaciones e IT, éste será encargado de actualizar los datos cada trimestre e incorporar variables externas (precio del combustible, tipo de cambios y condiciones climáticas), lo que aumentará la precisión de las previsiones. Además, incluir en los paneles indicadores de seguridad, medio ambiente y huella de carbono reforzará el cumplimiento de YPF y otros clientes dándole a Texrell un nivel de excelencia que otras compañías no tienen. Sugerimos la compra de nuevas flotas eléctricas, siendo Texrell la empresa en innovar en la primera grúa eléctrica abre paso al camino de futuras adquisiciones que la posicionaría en el rango líder en el mercado y de ésta manera sostendría el plan de desarrollo de sostenibilidad, además de incorporar sensores IoT para el mantenimiento predictivo y así lograr una buena vida útil de la flota y una atención especial en los recursos que utilizan aquellas Unidades de negocio y subunidades que son la columna vertebral de la operación.

Finalmente recomendamos a la empresa Texrell la creación de un panel de control específica para el cliente de YPF, debido a que el mismo representa casi un 50% de nuestros contratos, dichos contratos se encuentran con gran proporción deficitaria es por eso la importancia de tener un seguimiento continuo y actualizado de este cliente para futuras acciones en las firmas de contrato de este.

7. Limitaciones y futuras líneas de investigación

7.1. Limitaciones

A pesar de los avances alcanzados, el estudio presenta cuatro restricciones que conviene tener en cuenta. La primera tiene referencia a un periodo concreto analizado 2021-2024, en un contexto post pandemia podemos decir que las operaciones estuvieron condicionadas, por lo que las proyecciones podrían variar en un entorno macroeconómico más estable. La segunda limitación proviene de la granularidad de los datos, cuando la información se consolida solo al cierre de cada jornada, quedan afuera de nuestro radar las incidencias que surgen dentro del mismos días y que, aunque son puntuales, pueden alterar de forma sensible la rentabilidad del contrato, se deberían ajustar las tarifas automáticamente teniendo en cuenta los puntos que pueden incidir y así evitar fuga de costos en los contratos. De ahí la conveniencia de registrar los costes y las horas de operación con un nivel de detalle. Sólo con esa granularidad podremos estimar los márgenes para poder garantizar el análisis profundo y al detalle. Por último, otra limitación es que la vorágine del día a día pierde el foco de tener optimizados los recursos de aquellas unidades que tienen más demandas por lo que hay un gran recambio dentro de las operaciones de equipos por roturas, debería haber un seguimiento y mantenimiento predictivo para evitar estos desfasajes en las flotas.

7.2. Futuras líneas de investigación

Para poder superar las limitaciones señaladas se proponen tres líneas de trabajo:

1. Ampliar el modelo con variables exógenas como puede ser el precio del Diesel, el tipo de cambio, la inflación o las condiciones climatológicas, y comparar el rendimiento Random Forest con algoritmos como XGBoost, con el objetivo de elevar el R^2 por encima de 0,55.
2. Desarrollar un módulo de tarificación dinámica que ajuste automáticamente las propuestas comerciales en función de la probabilidad de alcanzar ese margen objetivo, maximizando así los ingresos en tiempo real, estas propuestas deberán ser ajustadas por contrato, con revisión periódica e implementadas en SAP para que el sector de contratos mantenga las tarifas actualizadas.

3. Implementar mantenimiento predictivo a la flota a través de IoT, así poder medir su impacto sobre todo en los recursos que son más demandados y requieren de un mantenimiento constante para poder brindar un servicio de calidad constante.

Con estas líneas de investigación, Texrell podrá consolidar una gestión aún más precisa, sostenible y orientada a la prestación de excelencia a largo plazo.

8. Acrónimos

Se presenta el siguiente listado de Acrónimos y sus Fuentes:

ADM: Administración y RRHH (unidad de negocio).

ALM: Servicios de gestión de almacenes (unidad de negocio).

ALQ: Tráileres y luminarias (unidad de negocio).

API: Application Programming Interface (Interfaz de Programación de Aplicaciones).

ARS: Pesos argentinos.

CO2: Dióxido de carbono.

DAFO: Debilidades, Amenazas, Fortalezas y Oportunidades.

DTM: Desmontaje, Transporte y Montaje (unidad de negocio).

EDA: Análisis Exploratorio de Datos.

EOL: Eólicos (unidad de negocio).

ERP: Enterprise Resource Planning (Planificación de Recursos Empresariales).

ESG: Environmental, Social, and Governance (Ambiental, Social y de Gobernanza).

GRI: Global Reporting Initiative.

GROOMT: Movimientos de suelo (unidad de negocio).

HVO: Hydrogenated Vegetable Oil (Aceite Vegetal Hidrogenado).

IDE: Entorno de Desarrollo Integrado.

IoT: Internet of Things (Internet de las Cosas).

ISO: International Organization for Standardization (Organización Internacional de Normalización).

KPIs: Key Performance Indicators (Indicadores Clave de Rendimiento).

MANT: Mantenimiento (unidad de negocio).

MSE: Mean Square Error (Error Cuadrático Medio).

MW: Megawatt.

ODS: Objetivo de Desarrollo de Sostenibilidad.

OV: Orden de Venta.

PCIA: Provincia.

PPA: Power Purchase Agreement (Acuerdo de Compra de Energía).

R²: R-squared (Coeficiente de determinación).

RCV: Rastreo de vehículos.

RMSE: Root Mean Squared Error (Raíz del Error Cuadrático Medio).

RRHH: Recursos Humanos.

RSE: Responsabilidad Social Empresarial.

SEM: Search Engine Marketing (Marketing en Motores de Búsqueda).

SEO: Search Engine Optimization (Optimización para Motores de Búsqueda).

SV: Servicios Viales (unidad de negocio).

TCL: Transporte de Líquidos (unidad de negocio).

TCS: Transporte de Sólidos (unidad de negocio).

TCFD: Task Force on Climate-related Financial Disclosures.

UE: Universidad Europea.

VAC: Vactor (unidad de negocio).

YPF: Yacimientos Petrolíferos Fiscales (cliente).

9. Referencias bibliográficas

Bishop, Christopher M. *Pattern Recognition and Machine Learning*. Softcover reprint of the original 1st edition 2006 (corrected at 8th printing 2009), Springer New York, 2016. «A Few Useful Things to Know about Machine Learning». *Communications of the ACM*, vol. 55, n.o 10, octubre de 2012, pp. 78-87. DOI.org (Crossref), <https://doi.org/10.1145/2347736.2347755>. Domingos, P.

Draper, Norman Richard, y Harry Smith. *Applied Regression Analysis*. Third edition, Wiley, 1998.

Ojeda, Silvia, et al. «La pobreza en los hogares del Gran Córdoba: aplicación del modelo de regresión logística». *Revista de Economía y Estadística*, vol. 43, n.o 1, junio de 2005, pp. 99-121. DOI.org (Crossref), <https://www.revistanefrologia.com/es-la-regresion-logistica-una-herramienta-articulo-X0211699505703015>

Barrientos Martínez, R. E., Cruz Ramírez, N., Acosta Mesa, H. G., Rabatte Suárez, I., Gogeoascoechea Trejo, M. del C., Pavón León, P., & Blázquez Morales, S. L. (2006). Árboles de decisión como herramienta en el diagnóstico médico. *ACIMED*, 14(2), 1–11. <http://scielo.sld.cu/pdf/aci/v14n2/aci05206.pdf>

Breiman, Leo. «[Random forests. Machine Learning]». *Machine Learning*, vol. 45, n.o 1, 2001, pp. 5-32. DOI.org (Crossref), <https://doi.org/10.1023/A:1010933404324> .

McKinney, Wes. *Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython*. Second edition, Fourth release, O'Reilly, 2018.

Géron, Aurélien. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 2nd Edition. [Place of publication not identified] O'Reilly Media, 2019.

Render, B., Stair, R. M., & Hanna, M. E. (2012). *Métodos cuantitativos para los negocios* (11ª ed., M. A. González Osuna, Trad.). Pearson. (Obra original publicada en inglés como *Quantitative Analysis for Management*)

Instituto Argentino del Petróleo y Gas (IAPG): <https://iapg.org.ar/>

Empresa de Referencia: <https://www.crexellsa.com/>

Pérez, J. (2021). *Logística petrolera en el siglo XXI: desafíos y actores clave*. Buenos Aires: Ediciones Técnicas del Sur.

Economía y Energía en Vaca Muerta:
<https://www.argentina.gob.ar/economia/energia/vaca-muerta>

ERP - SAP: <https://www.sap.com/spain/products/erp/what-is-erp.html>

Business Analytics - significado y tipo de análisis: <https://kschool.com/blog/analitica-web/que-es-business-analytics>

Business Analytics - definición: <https://isdfundacion.org/2023/06/15/que-es-el-business-analytics-definicion-y-usos/>

Cadena de Valor: https://es.wikipedia.org/wiki/Cadena_de_valor

Logística de entrada: <https://www.rsv.com.ar/>

Relaciones Institucionales con Mapuches: <https://www.swissinfo.ch/spa/la-provincia-de-neuqu%c3%a9n-negocia-con-los-mapuches-para-pacificar-vaca-muerta>

https://www.researchgate.net/publication/366670020_Conflictos_y_demandas_indigenas_por_el_territorio_frente_al_avance_de_la_frontera_hidrocarburifera_en_la_provincia_de_Neuquen_Argentina

APIs: Integración en la logística: <https://www.beetrack.com/es/blog/integraciones-api-automatizacion-logistica/> / <https://bagsack.com.mx/apis-y-logistica/>

Dashboards: <https://todobi.com/best-powerbi-and-dashboard-designs/>

Dashboards: tipos <https://blog.qservus.com/tipos-de-dashboard-estrategicos-operativos-analiticos/>

DAFO: Kotler, P. & Armstrong, G. (2018). *Fundamentos de Marketing*. Pearson Educación.

Objetivo de Desarrollo Sostenible (ODS): Karavalakis, G., et al. (2022). Effects of hydrogenated vegetable oil (HVO) and HVO/biodiesel blends on emissions from an off-road heavy-duty engine. *Fuel*, 323, 124283.

Martínez, J. D. (2021). An overview of the end-of-life tires status in some Latin American countries: Proposing pyrolysis for a circular economy. *Renewable and Sustainable Energy Reviews*, 144, 111009.

SAP SE. (2024). SAP Sustainability Control Tower – Product Overview. <https://www.sap.com/>

Touriño, J. (2023). “Argentina to add 2.5 GW of renewables in ten northern provinces.” *PV Tech*, 28 septiembre 2023.

Vergez, G., & Nawel, J. (2023). “Informe ante el Tribunal Internacional de Derechos de la Naturaleza sobre Vaca Muerta.” *Rights of Nature Tribunal*.

Worland, J. (2024). “Inside Fatih Birol’s Push to Transform the IEA into a Clean Energy Authority.” *TIME*, 23 febrero 2024.

International Organization for Standardization (ISO). (2019). ISO 14064-3:2019 Greenhouse gases — Part 3: Specification with guidance for the verification and validation of greenhouse gas statements. Ginebra: ISO.

internacional Energy Agency (IEA). 2024. Electric Trucks: Energy and Cost Savings Outlook.

Principles for Responsible Investment (PRI). 2023. Incentive Alignment and Sustainability.

Global Reporting Initiative (GRI). (2021). External Assurance of Sustainability Reporting.

Eccles, R. G., & Taylor, A. (2023). The Evolving Role of Chief Sustainability Officers. Harvard Business Review.

Banco de la Nación Argentina. (2024). Programa de Reconversión y Eficiencia Energética.

10. Anexos

Anexo A Validación del Trabajo

Se realizó una sesión de 40 minutos a través de la herramienta de Teams, sirvió para validar resultados con quienes serían nuestro público objetivo: el Gerente comercial Pedro Martínez y Valentina Acassuso, responsable de certificación del contrato de YPF, tras una demostración guiada de los dashboard y del modelo predictivo, el dialogo giró en torno a cuatro ejes, relevancia estratégica, viabilidad operativa, consistencia de datos y potencial de escalabilidad.

Principales comentarios de Pedro Martínez, subrayó que la vista unificada de margen de contrato permite eliminar la fragmentación y da pauta a tener un panorama más amplio a la hora de renegociar el 40% de los acuerdos deficitarios en evaluación del próximo trimestre comercial, destaco además la utilizas inmediata del filtro de riesgo basado en Random Forest: cualquier licitación con una probabilidad de pérdida superior al 35% se devuelve ahora al área para su revisión. Con éstas dos medidas prevé un aumento de tres puntos porcentuales en el margen neto anual y una reducción del 25% en las horas dedicadas al análisis de rentabilidad. Algo que refuerza es que tanto la unidad de grúas como la de transportes de cargas especiales es verdad que están sobrecargados y son las unidades que más salud y mantenimiento deberían tener con respecto a planeamiento y recambio de equipos para que no caiga la calidad del servicio. Por otro lado destaca la problemática de YPF, es quien representa el contrato de mayor índole financiero y demanda mayor atención tanto en la deuda contractual, como en los recursos que se están utilizando y hemos visto a lo largo de todo el TFM, que en todos los años ha sido el contrato que lidera el ranking, es por ello que acompaña y valida nuestro análisis y nos invita a que si quisiéramos mostrar a futuro un análisis más profundo basándonos solo en este contrato para poder ver patrones ocultos que la compañía debería tener en cuenta.

Principales Comentarios de Valentina Acassuso, confirmó que los indicadores del cuadro de mando se ajustan al formato exigido por YPF, lo que puede reducir incidencias en la facturación como los tiempos de certificación en torno a un 30%. Propuso incorporar la matriz de riesgos HSE para que las tarifas recojan de forma explícita el coste de las medidas preventivas y evitar así rechazos de las auditorías. Insistió, asimismo, en la necesidad de un procedimiento de contraste entre los datos de SAP y los partes diarios de

la operación, hay una demora importante al llegar los partes y eso también demora el cobro de los servicios, además hoy por hoy YPF tiene 12 inspecciones y la más grande del contrato no exige firma de supervisores y eso permite que el proceso fluya de una manera más dinámica, pero el resto de las inspecciones si lo exige y es un contratiempo a la hora de ser eficientes. Por último, resaltó el valor reputacional de demostrar que la certificación de YPF es quien en estos momentos está teniendo más carga administrativa y también solicitó a gerencia una persona más en la parte administrativa para agilizar los tiempos.

En síntesis de la reunión, la dirección coincide en el que el proyecto ofrece una ventaja competitiva: integra métricas de rentabilidad, sostenibilidad y riesgo en un único entorno, agiliza la toma de decisiones y allana el proceso de certificación, dándole relevancia a los contratos más demandantes y acompañando el plan de vida útil de los recursos asignados a las unidades de negocio que son más emblemáticas para la compañía, sin olvidar dar un empuje y un refresh a aquellas que han quedado rezagadas o dormidas a nivel operacional, hay que impulsarlas en nuevos contratos o reciclar aquellos ya existentes.

Anexo B Carga de datos y visualización inicial de Columnas:

```
import pandas as pd
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt
import datetime as dt
import random
```

Python

```
df = pd.read_csv(r"C:\Users\Patricia Versuti\Desktop\Anging Texrell.csv")
df
```

Python

#	#	TIPO	UN	SUBUI
0	1	SAP.FAC	UN-SSV	SSV-03
1	2	SAP.FAC	UN-TCL	TCL-01
2	3	SAP.FAC	UN-VAC	VAC-01
3	4	SAP.FAC	UN-GRU	GRU-01
4	5	SAP.FAC	UN-DTM	DTM-02
5	6	SAP.FAC	UN-GRU	GRU-01
6	7	SAP.FAC	UN-GRU	GRU-01
7	8	SAP.FAC	UN-GRU	GRU-01
8	9	SAP.FAC	UN-VAC	VAC-01
9	10	SAP.FAC	UN-GRU	GRU-01

107,289 rows x 41 cols | 10 per page | Page 1 of 10729

Anexo C Limpieza de Datos:

```
df.columns

Index(['#', 'TIPO', 'UN', 'SUBUN', 'PCIA', 'CLIENTE', 'XLS.Id', 'VTA.Id',
      'VTA.Estado', 'VTA.Fecha', 'ItemCode', 'ItemDesc', 'CANTIDAD_dias',
      'PRECIO', 'IMPORTE', 'PENDIENTE', 'Periodo', 'LLS', 'PCIA.1', 'ESTADO',
      'LLS Cant', 'LLS Fec.Fin', 'DIAS', 'GRUPO', 'MENOS0', 'DE0A15',
      'DE15A30', 'DE30A60', 'DE60A90', 'DE90A120', 'MAS120', 'ERROR',
      'EMPLEADO', 'PROYECTO', 'DOCMEDYPF', 'COMENTARIO', 'HABILITA', 'EQUIPO',
      'INSPECTOR', 'AREA', 'SDS'],
      dtype='object')
```

```
df = df[['Periodo', 'CLIENTE', 'PCIA', 'ItemDesc', 'CANTIDAD_dias', 'PRECIO', 'IMPORTE']].dropna()
#filtrando precios acima de 1
df = df[df['PRECIO'] > 0]
df = df[df['CANTIDAD_dias'] > 0].rename(columns={'CANTIDAD_dias': 'CANTIDAD_DIAS'})
df = df[df['IMPORTE'] > 0]
df = df.rename(columns={'ItemDesc': 'ITEM_DESC', 'Periodo': 'PERIODO'})
df[['CANTIDAD_DIAS', 'PRECIO', 'IMPORTE']] = df[['CANTIDAD_DIAS', 'PRECIO', 'IMPORTE']].astype(np.float64)
df['PERIODO'] = pd.to_datetime(df['PERIODO'])
df['PERIODO'] = df['PERIODO'].dt.strftime('%Y-%m')
df = df[(df['PERIODO'] >= '2021-01') & (df['PERIODO'] <= '2024-12')]
```

```
#dividir los precios por 1300
df['PRECIO'] = df['PRECIO'] / 1300
#dividir los importes por 1300
df['IMPORTE'] = df['IMPORTE'] / 1300
#ajustar para mostrar 2 decimales
df['PRECIO'] = df['PRECIO'].round(2)
df['IMPORTE'] = df['IMPORTE'].round(2)
```

```
df = df[~df['ITEM_DESC'].str.upper().str.startswith(('MOVIL', 'TRANSP'))]
```

```
def generalizar_item(desc):
    desc = desc.upper()
    if "GRUA" in desc:
        return "GRUA"
    elif "MANLIFT" in desc:
        return "MANLIFT"
    elif "CARRETÓN" in desc or "CARRETON" in desc:
        return "CARRETON"
    elif "PALA" in desc:
        return "PALA"
    elif "SEMIREMOLQUE" in desc:
        return "SEMIREMOLQUE"
    elif "TRAILER" in desc:
        return "TRAILER"
    elif "CAMION" in desc or "PETROLERO" in desc:
        return "CAMION"
    else:
        return desc
```

Anexo D Selección de columnas:

```
categorias = ["GRUA", "MANLIFT", "CARRETON", "PALA", "SEMIREMOLQUE", "TRAILER", "CAMION"]
df = df[df['ITEM_DESC'].isin(categorias)]
```

Anexo E Creación de coste porcentual:

```
random.seed(42) # Escolha qualquer número fixo

def coste_porcentual(row):
    categoria = row['ITEM_DESC']
    importe = row['IMPORTE']
    if categoria == "GRUA":
        pct = random.uniform(0.40, 0.60)
    elif categoria == "MANLIFT":
        pct = random.uniform(0.35, 0.50)
    elif categoria == "CARRETON":
        pct = random.uniform(0.45, 0.60)
    elif categoria == "PALA":
        pct = random.uniform(0.30, 0.45)
    elif categoria == "SEMIREMOLQUE":
        pct = random.uniform(0.40, 0.55)
    elif categoria == "TRAILER":
        pct = random.uniform(0.35, 0.50)
    elif categoria == "CAMION":
        pct = random.uniform(0.50, 0.65)
    else:
        pct = 0
    return round(importe * pct, 2)

df['COSTE_TOTAL'] = df.apply(coste_porcentual, axis=1)
```

Python

Anexo F Verificación de nombres y tipos de variables:

```
print("=== Nombres y tipos de variables ===")
print(df.dtypes)
print("\n")
```

Python

```
=== Nombres y tipos de variables ===
PERIODO      object
CLIENTE      object
PCIA         object
ITEM_DESC    object
CANTIDAD_DIAS float64
PRECIO       float64
IMPORTE      float64
COSTE_TOTAL  float64
dtype: object
```

Anexo G Resumen estadístico:

```
print("=== Resumen estadístico ===")
print(df.describe(include='all').T)
print("\n")
```

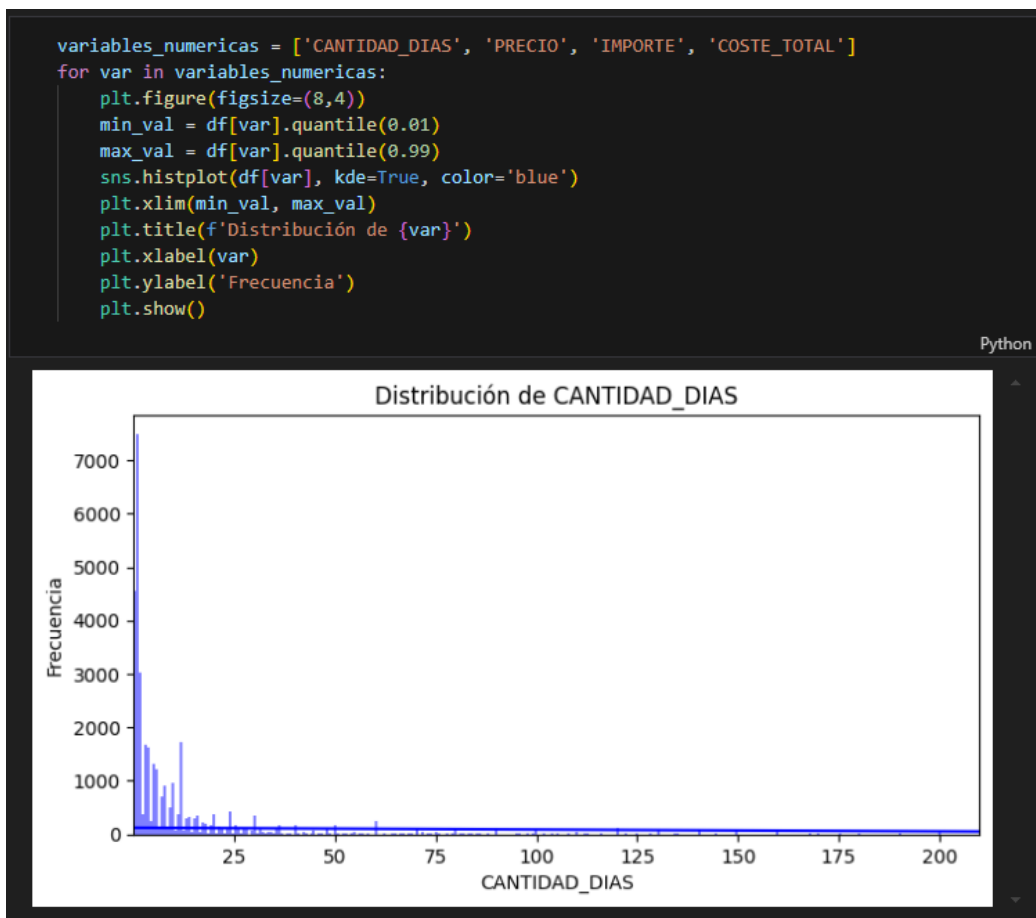
Python


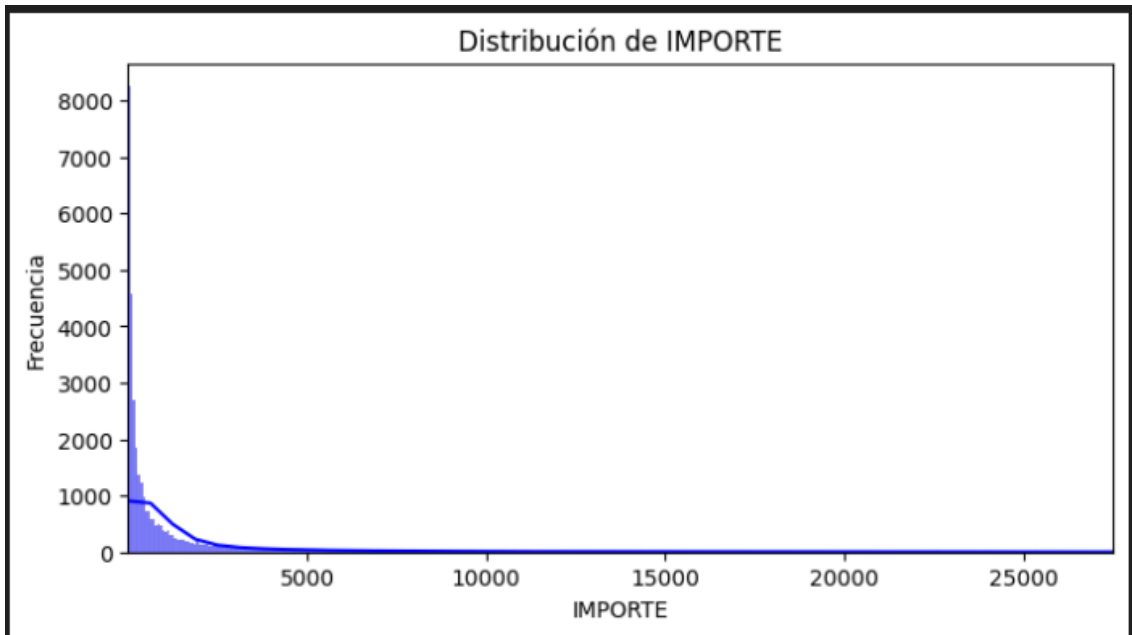
```
=== Resumen estadístico ===
```

	count	unique	top	freq	mean	std	min	\
PERIODO	34955	48	2023-10	919	NaN	NaN	NaN	
CLIENTE	34955	241	YPF	17499	NaN	NaN	NaN	
PCIA	34955	18	NEUQUEN	31897	NaN	NaN	NaN	
ITEM_DESC	34955	7	GRUA	18376	NaN	NaN	NaN	
CANTIDAD_DIAS	34955.0	NaN	NaN	NaN	26.335716	586.354469	0.01	
PRECIO	34955.0	NaN	NaN	NaN	1976.726161	7629.866745	0.0	
IMPORTE	34955.0	NaN	NaN	NaN	1965.682774	5673.652434	0.1	
COSTE_TOTAL	34955.0	NaN	NaN	NaN	985.208325	2865.15362	0.04	

	25%	50%	75%	max
PERIODO	NaN	NaN	NaN	NaN
CLIENTE	NaN	NaN	NaN	NaN
PCIA	NaN	NaN	NaN	NaN
ITEM_DESC	NaN	NaN	NaN	NaN
CANTIDAD_DIAS	1.0	4.0	12.0	72575.91
PRECIO	7.91	89.9	463.87	90327.21
IMPORTE	73.125	277.52	1184.81	124572.7
COSTE_TOTAL	36.135	136.26	595.46	69094.82

Anexo H Gráficos de distribución de datos numéricos

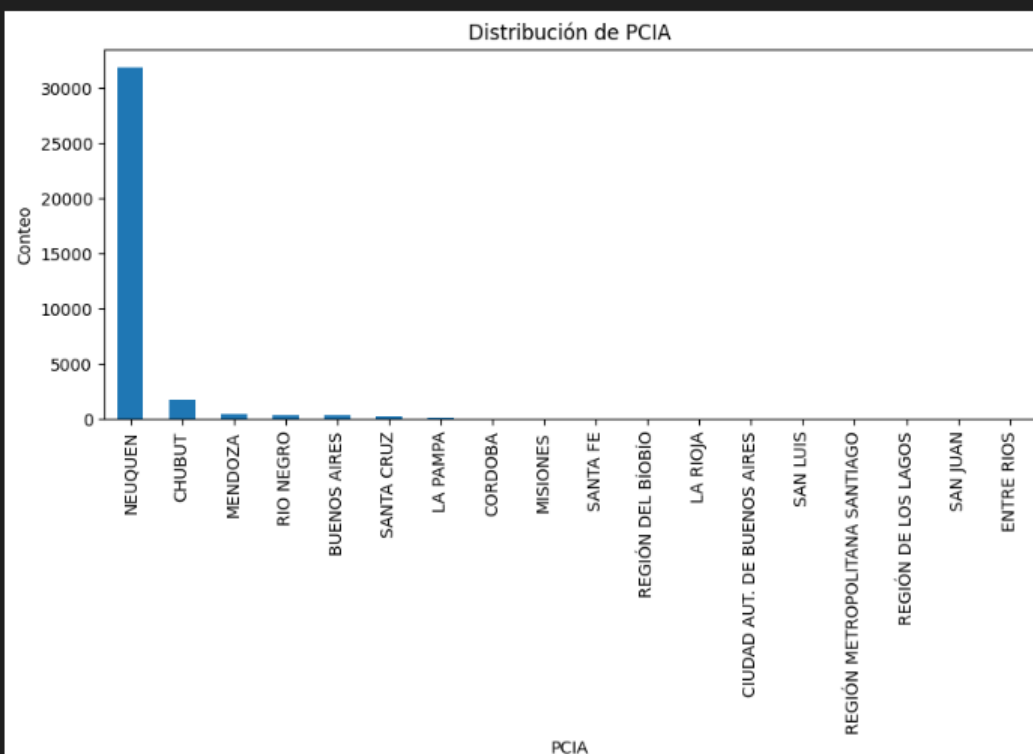
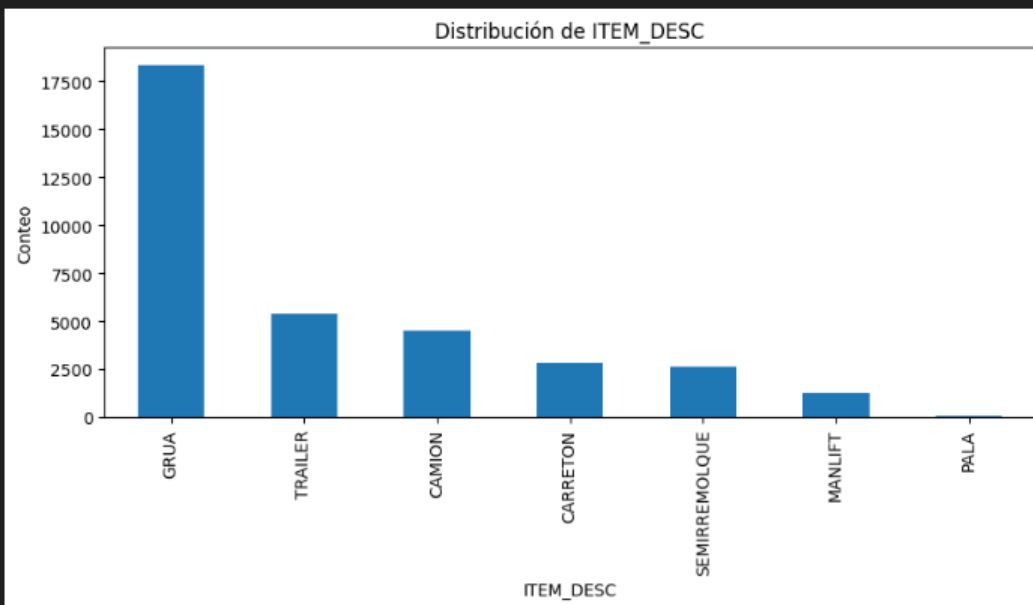





Anexo H Gráficos de distribución de datos categóricos

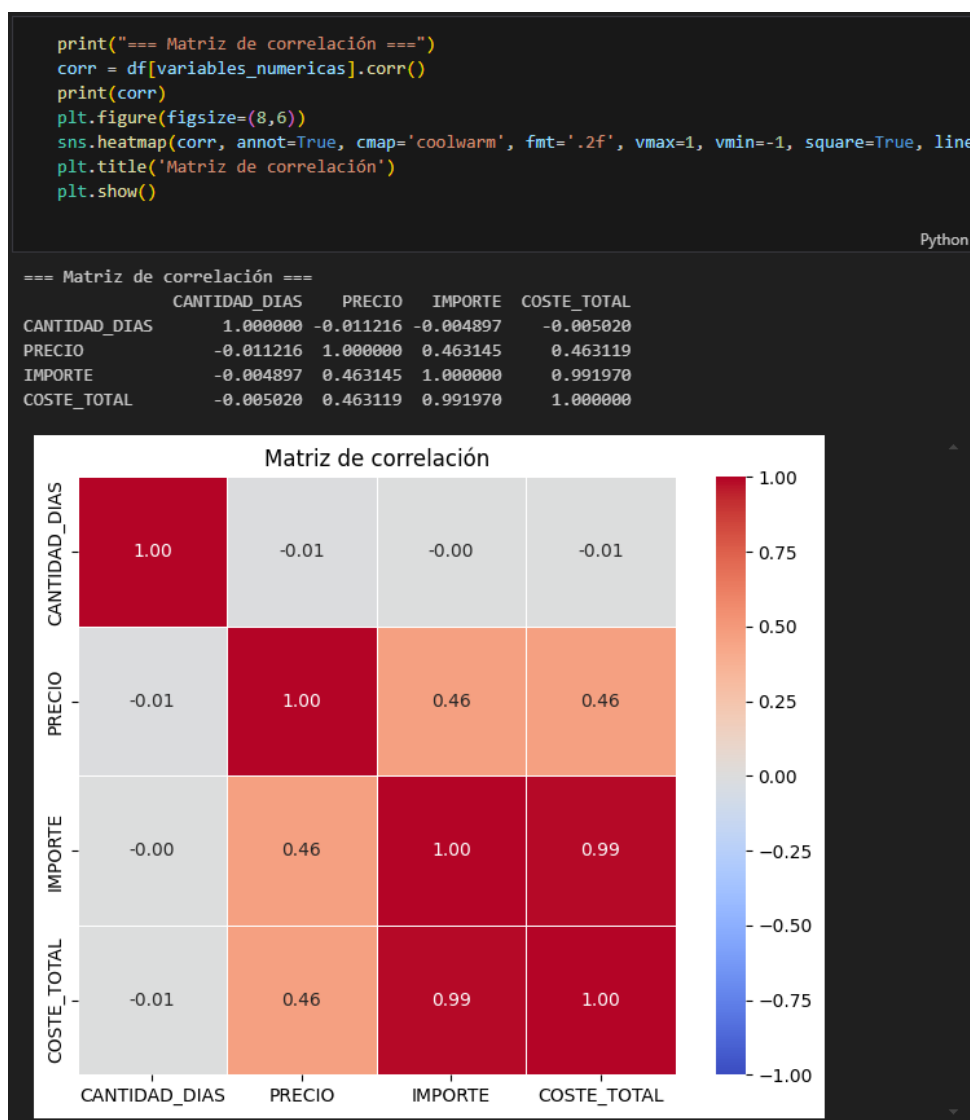
```
variables_categoricas = ['ITEM_DESC', 'PCIA', 'PERIODO']
for var in variables_categoricas:
    plt.figure(figsize=(10,4))
    df[var].value_counts().plot(kind='bar')
    plt.title(f'Distribución de {var}')
    plt.xlabel(var)
    plt.ylabel('Conteo')
    plt.show()
```

Python





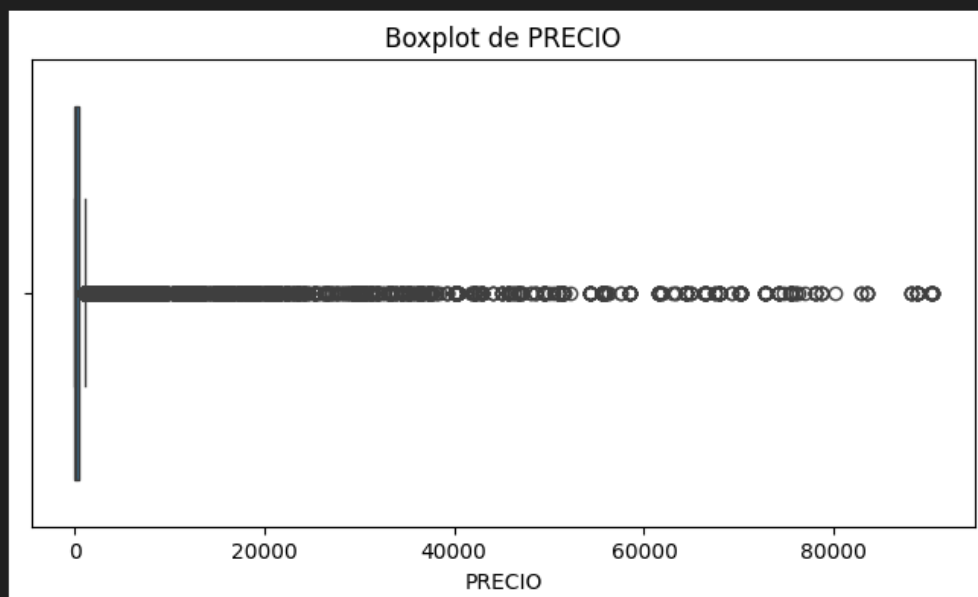

Anexo I Gráficos matrices de correlación





Anexo J Gráficos de caja y bigotes

```
for var in variables_numericas:  
    plt.figure(figsize=(8,4))  
    sns.boxplot(x=df[var])  
    plt.title(f'Boxplot de {var}')  
    plt.xlabel(var)  
    plt.show()
```

Python

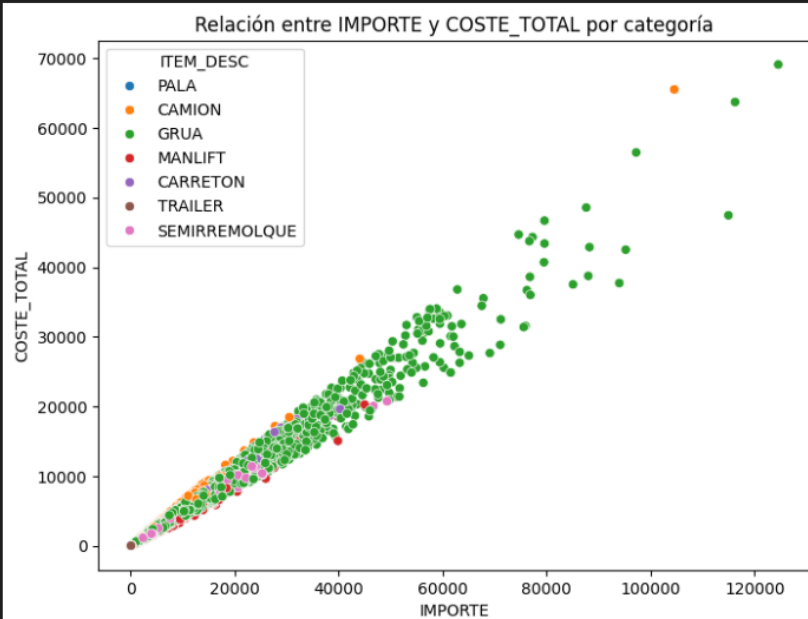




Anexo K Gráficos relacionales entre costo y importe

```
plt.figure(figsize=(8,6))
sns.scatterplot(x='IMPORTE', y='COSTE_TOTAL', hue='ITEM_DESC', data=df)
plt.title('Relación entre IMPORTE y COSTE_TOTAL por categoría')
plt.xlabel('IMPORTE')
plt.ylabel('COSTE_TOTAL')
plt.legend(title='ITEM_DESC')
plt.show()
```


Python



Anexo L Gráficos histórico mensual de importe

```
importe_mensual = df.groupby('PERIODO')['IMPORTE'].sum()
plt.figure(figsize=(12,5))
importe_mensual.plot(marker='o')
plt.title('Evolución mensual del IMPORTE total')
plt.xlabel('PERIODO')
plt.ylabel('IMPORTE total')
plt.xticks(rotation=45)
plt.grid(True)
plt.show()
```

Python



Anexo M Preparación de datos para el modelo

```
from sklearn.compose import ColumnTransformer
from sklearn.preprocessing import OneHotEncoder
from sklearn.pipeline import Pipeline
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split, KFold, cross_val_score
from sklearn.metrics import mean_squared_error, r2_score, make_scorer
import pandas as pd
import numpy as np

# Feature engineering
df['MARGEN'] = (df['IMPORTE'] - df['COSTE_TOTAL']) / df['IMPORTE']
X = df[['CLIENTE', 'PCIA', 'ITEM_DESC', 'CANTIDAD_DIAS', 'IMPORTE']]
y = df['MARGEN']

# Separação
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Pré-processamento
categorical_features = ['CLIENTE', 'PCIA', 'ITEM_DESC']
numeric_features = ['CANTIDAD_DIAS', 'IMPORTE']

preprocessor = ColumnTransformer(transformers=[
    ('cat', OneHotEncoder(handle_unknown='ignore'), categorical_features)
], remainder='passthrough') # mantém numéricas

# Modelo
rf = RandomForestRegressor(n_estimators=100, random_state=42)

# Pipeline completo
model = Pipeline(steps=[
    ('preprocessor', preprocessor),
    ('regressor', rf)
])
```

Python

Anexo N Reporte de evaluación de variables importantes de modelo

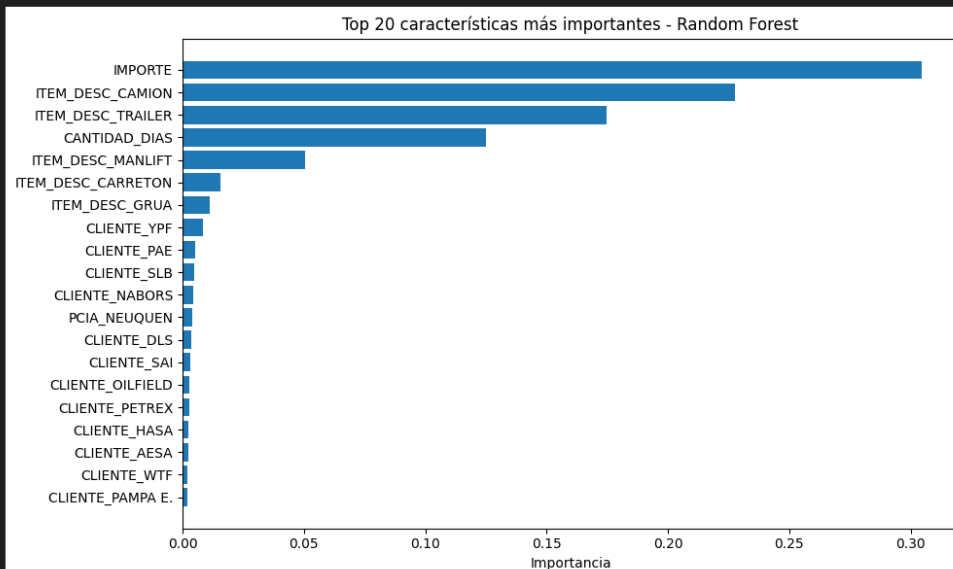
```
# Obtienes la importancia de cada característica (corregido)
importancias = model.named_steps['regressor'].feature_importances_

# Obtener nombres de características
ohe = model.named_steps['preprocessor'].named_transformers_['cat']
ohe_feature_names = ohe.get_feature_names_out(categorical_features)
feature_names = np.concatenate([ohe_feature_names, numeric_features])

# Las combinas con los nombres de las columnas
importancia_df = pd.DataFrame({
    'feature': feature_names,
    'importance': importancias
}).sort_values(by='importance', ascending=False)

# Mostrar solo las 20 más importantes
top_n = 20
top_features = importancia_df.head(top_n)

# Mostrar solo las 20 más importantes
plt.figure(figsize=(10, 6))
plt.barh(top_features['feature'], top_features['importance'])
plt.xlabel('Importancia')
plt.title(f'Top {top_n} características más importantes - Random Forest')
plt.gca().invert_yaxis()
plt.tight_layout()
plt.show()
```



Anexo O Modelo para estimación por contrato

```
ejemplo = pd.DataFrame([{
    'CLIENTE': 'SECCO',
    'PCIA': 'NEUQUEN',
    'ITEM_DESC': 'GRUA',
    'CANTIDAD_DIAS': 10,
    'IMPORTE': 1000
}])
margen_predicho = model.predict(ejemplo)[0]
print(f"Margen estimado para el contrato: {margen_predicho:.2%}")
```

Margen estimado para el contrato: 50.18%

Anexo P Base de datos importada Power Bi

PERIODO	CLIENTE	PCIA	ITEM DESC	CANTIDAD DIAS	PRECIO	IMPORTE	COSTE TOTAL	MARGEN	Mes	Día de Semana	Cuatrimestre	Contrato Definitivo	Total Contratos en Pérdida	Margen Real	Rango de Duración	
Friday, April 1, 2022	VFF	NEUQUEN	GRUA	1	\$135.64	\$135.64	\$77.63	42.77%	4	Friday		2	Margen Bajo		58.01	Corto Plazo
Sunday, September 1, 2024	VFF	NEUQUEN	GRUA	1	\$2,274.24	\$2,274.24	\$1,118.4	50.82%	9	Sunday		3	OK		1155.84	Corto Plazo
Friday, December 1, 2023	VFF	NEUQUEN	GRUA	1	\$566.23	\$566.23	\$325.92	42.44%	12	Friday		4	Margen Bajo		240.31	Corto Plazo
Friday, November 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,143.05	\$1,143.05	\$631.1	44.79%	11	Friday		4	Margen Bajo		\$71.95	Corto Plazo
Thursday, June 1, 2023	VFF	NEUQUEN	GRUA	1	\$7,162.23	\$7,162.23	\$2,688.15	59.84%	6	Thursday		2	OK		4304.08	Corto Plazo
Thursday, August 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,059.4	\$1,058.34	\$593.14	43.96%	8	Thursday		3	Margen Bajo		465.2	Corto Plazo
Wednesday, May 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,012.12	\$1,012.12	\$550.54	45.61%	5	Wednesday		2	OK		461.58	Corto Plazo
Saturday, June 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,481.07	\$1,481.07	\$856.48	42.17%	6	Saturday		2	Margen Bajo		624.59	Corto Plazo
Saturday, October 1, 2022	VFF	NEUQUEN	GRUA	1	\$172.16	\$172.16	\$85.31	50.43%	10	Saturday		4	OK		86.85	Corto Plazo
Saturday, April 1, 2023	VFF	NEUQUEN	GRUA	1	\$181.96	\$181.96	\$97.8	46.25%	4	Saturday		2	OK		84.16	Corto Plazo
Wednesday, June 1, 2022	VFF	NEUQUEN	GRUA	1	\$81.26	\$81.26	\$47.96	40.98%	6	Wednesday		2	Margen Bajo		33.3	Corto Plazo
Saturday, June 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,348.78	\$1,348.78	\$612.21	54.61%	6	Saturday		2	OK		736.57	Corto Plazo
Friday, July 1, 2022	VFF	NEUQUEN	GRUA	1	\$93.44	\$93.44	\$46.17	50.59%	7	Friday		3	OK		47.27	Corto Plazo
Monday, March 1, 2021	VFF	NEUQUEN	GRUA	1	\$82.33	\$82.33	\$43.31	53.09%	3	Monday		1	OK		49.02	Corto Plazo
Saturday, October 1, 2022	VFF	NEUQUEN	GRUA	1	\$148.48	\$148.48	\$80.1	46.05%	10	Saturday		4	OK		68.38	Corto Plazo
Wednesday, December 1, 2021	VFF	NEUQUEN	GRUA	1	\$70.35	\$70.35	\$36.23	48.50%	12	Wednesday		4	OK		34.12	Corto Plazo
Wednesday, May 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,211.12	\$1,211.12	\$589.79	52.85%	5	Wednesday		2	OK		641.33	Corto Plazo
Monday, February 1, 2021	VFF	NEUQUEN	GRUA	1	\$2,19.72	\$2,19.72	\$120.74	45.05%	2	Monday		1	OK		86.80	Corto Plazo
Monday, July 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,375.56	\$1,375.56	\$639.07	46.74%	7	Monday		3	OK		736.49	Corto Plazo
Friday, October 1, 2021	VFF	NEUQUEN	GRUA	1	\$390.52	\$390.52	\$161.57	58.63%	10	Friday		4	OK		228.95	Corto Plazo
Thursday, September 1, 2022	VFF	NEUQUEN	GRUA	1	\$133.32	\$133.32	\$62.42	53.18%	9	Thursday		3	OK		70.9	Corto Plazo
Monday, March 1, 2021	VFF	NEUQUEN	GRUA	1	\$252.36	\$252.36	\$111.81	55.77%	3	Monday		1	OK		140.75	Corto Plazo
Wednesday, December 1, 2021	VFF	NEUQUEN	GRUA	1	\$70.35	\$70.35	\$40.02	43.17%	12	Wednesday		4	Margen Bajo		30.33	Corto Plazo
Sunday, January 1, 2023	VFF	NEUQUEN	GRUA	1	\$131.44	\$131.44	\$58.97	55.14%	1	Sunday		1	OK		72.47	Corto Plazo
Monday, February 1, 2021	VFF	NEUQUEN	GRUA	1	\$52.33	\$52.33	\$28.88	44.81%	2	Monday		1	Margen Bajo		23.45	Corto Plazo
Monday, April 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,881.45	\$1,881.45	\$997.86	46.96%	4	Monday		2	OK		883.59	Corto Plazo
Tuesday, October 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,447.85	\$1,447.85	\$725.24	49.91%	10	Tuesday		4	OK		722.61	Corto Plazo
Saturday, May 1, 2021	VFF	NEUQUEN	GRUA	1	\$404.32	\$404.32	\$212.32	51.12%	5	Saturday		2	OK		222.01	Corto Plazo
Thursday, February 1, 2024	VFF	NEUQUEN	GRUA	1	\$545.27	\$545.27	\$233.77	57.13%	2	Thursday		1	OK		311.5	Corto Plazo
Thursday, July 1, 2021	VFF	NEUQUEN	GRUA	1	\$89.35	\$89.35	\$49.7	44.38%	7	Thursday		3	Margen Bajo		39.65	Corto Plazo
Thursday, February 1, 2024	VFF	NEUQUEN	GRUA	1	\$545.27	\$545.27	\$231.48	57.55%	2	Thursday		1	OK		312.79	Corto Plazo
Friday, December 1, 2023	VFF	NEUQUEN	GRUA	1	\$223.68	\$223.68	\$177.46	49.82%	12	Friday		4	OK		176.22	Corto Plazo
Monday, January 1, 2024	VFF	NEUQUEN	GRUA	1	\$441.28	\$441.28	\$216.32	51.05%	1	Monday		1	OK		225.96	Corto Plazo
Tuesday, June 1, 2021	VFF	NEUQUEN	GRUA	1	\$1,048.95	\$1,048.95	\$622.29	40.67%	6	Tuesday		2	Margen Bajo		426.66	Corto Plazo
Tuesday, February 1, 2022	VFF	NEUQUEN	GRUA	1	\$95.66	\$95.66	\$40.64	57.52%	2	Tuesday		1	OK		55.02	Corto Plazo
Friday, July 1, 2022	VFF	NEUQUEN	GRUA	1	\$93.44	\$93.44	\$38.75	58.35%	7	Friday		3	OK		54.69	Corto Plazo
Sunday, December 1, 2024	VFF	NEUQUEN	GRUA	1	\$245.15	\$245.15	\$119.53	50.57%	12	Sunday		4	OK		125.62	Corto Plazo
Monday, February 1, 2021	VFF	NEUQUEN	GRUA	1	\$74.34	\$74.34	\$42.24	43.18%	2	Monday		1	Margen Bajo		32.1	Corto Plazo
Friday, April 1, 2022	VFF	NEUQUEN	GRUA	1	\$80.87	\$80.87	\$33.36	58.73%	4	Friday		2	OK		47.51	Corto Plazo
Saturday, June 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,481.07	\$1,481.07	\$750.95	49.30%	6	Saturday		2	OK		730.12	Corto Plazo
Wednesday, February 1, 2023	VFF	NEUQUEN	GRUA	1	\$5,889.39	\$5,889.39	\$2,428.93	58.78%	2	Wednesday		1	OK		3460.46	Corto Plazo
Saturday, July 1, 2023	VFF	NEUQUEN	GRUA	1	\$233.73	\$233.73	\$110.56	50.58%	7	Saturday		3	OK		112.17	Corto Plazo
Thursday, December 1, 2022	VFF	NEUQUEN	GRUA	1	\$147.9	\$147.9	\$70.47	52.35%	12	Thursday		4	OK		77.43	Corto Plazo
Saturday, July 1, 2023	VFF	NEUQUEN	GRUA	1	\$466.84	\$466.84	\$216.68	53.99%	7	Saturday		3	OK		250.16	Corto Plazo
Monday, July 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,575.56	\$1,575.56	\$804.01	47.07%	7	Monday		3	OK		741.55	Corto Plazo
Thursday, September 1, 2022	VFF	NEUQUEN	GRUA	1	\$1,158.06	\$1,158.06	\$1,382.07	56.24%	9	Thursday		3	OK		175.98	Corto Plazo
Friday, January 1, 2021	VFF	NEUQUEN	GRUA	1	\$60.27	\$60.27	\$29.89	50.41%	1	Friday		1	OK		30.38	Corto Plazo
Wednesday, September 1, 2021	VFF	NEUQUEN	GRUA	1	\$89.55	\$89.55	\$44.61	50.18%	9	Wednesday		3	OK		44.94	Corto Plazo
Wednesday, May 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,292.7	\$1,292.7	\$796.06	42.84%	5	Wednesday		2	Margen Bajo		596.64	Corto Plazo
Wednesday, November 1, 2023	VFF	NEUQUEN	GRUA	1	\$546.27	\$546.27	\$273.22	49.98%	11	Wednesday		4	OK		273.05	Corto Plazo
Sunday, December 1, 2024	VFF	NEUQUEN	GRUA	1	\$42,504.47	\$42,504.47	\$19,897.13	53.19%	12	Sunday		4	OK		22607.34	Corto Plazo
Sunday, September 1, 2024	VFF	NEUQUEN	GRUA	1	\$1,683.45	\$1,683.45	\$895.62	46.79%	9	Sunday		3	OK		787.83	Corto Plazo
Sunday, October 1, 2023	VFF	NEUQUEN	GRUA	1	\$315.09	\$315.09	\$163.46	48.12%	10	Sunday		4	OK		151.63	Corto Plazo
Friday, December 1, 2023	VFF	NEUQUEN	GRUA	1	\$486.82	\$486.82	\$224.39	53.91%	12	Friday		4	OK		262.43	Corto Plazo
Wednesday, February 1, 2021	VFF	NEUQUEN	GRUA	1	\$177.19	\$177.19	\$91.41	46.14%	3	Wednesday		1	OK		81.78	Corto Plazo

Anexo Q Base de datos ubicaciones

PCIA	UBICACION	X LONGITUD	Y LATITUD
RIO NEGRO	-39.0333, -67.5758	-39.0333	-67.5758
NEUQUEN	-38.9516, -68.0591	-38.9516	-68.0591
CHUBUT	-43.3002, -65.1023	-43.3002	-65.1023
MENDOZA	-32.8895, -68.8458	-32.8895	-68.8458
BUENOS AIRES	-34.6037, -58.3816	-34.6037	-58.3816
SANTA CRUZ	-48.7764, -69.2334	-48.7764	-69.2334
LA PAMPA	-36.6167, -64.2833	-36.6167	-64.2833
SANTA FE	-31.6333, -60.7000	-31.6333	-60.7
REGIÓN DE LOS LAGOS	-41.4717, -72.9369	-41.4717	-72.9369
REGIÓN DEL BÍO BÍO	-37.0, -72.0	-37	-72
CORDOBA	-31.4201, -64.1888	-31.4201	-64.1888
REGIÓN DE LA ARAUCANÍA	-38.7359, -72.5904	-38.7359	-72.5904
REGIÓN METROPOLITANA SANTIAGO	-33.4489, -70.6693	-33.4489	-70.6693
REGIÓN DE VALPARAÍSO	-33.0472, -71.6127	-33.0472	-71.6127
CIUDAD AUT. DE BUENOS AIRES	-34.6037, -58.3816	-34.6037	-58.3816
LA RIOJA	-29.4131, -66.8558	-29.4131	-66.8558
CORRIENTES	-27.4691, -58.8301	-27.4691	-58.8301
MISIONES	-27.3622, -55.9009	-27.3622	-55.9009
SAN LUIS	-33.3017, -66.3362	-33.3017	-66.3362
REGIÓN DEL MAULE	-35.4264, -71.6554	-35.4264	-71.6554
SALTA	-24.7821, -65.4232	-24.7821	-65.4232
REGIÓN DE ATACAMA	-27.3668, -70.3321	-27.3668	-70.3321
ENTRE RIOS	-31.7319, -60.5238	-31.7319	-60.5238
SAN JUAN	-31.5375, -68.5256	-31.5375	-68.5256
REGIÓN DE LOS RÍOS	-39.8142, -73.2459	-39.8142	-73.2459

Anexo R Conexión entre tabla



Anexo S Fórmula para nuevas columnas

```
1 Rango de Duración =  
2 SWITCH(  
3   TRUE(),  
4   'Anging Texrell Ajustado'[CANTIDAD_DIAS] <= 60, "Corto Plazo",  
5   'Anging Texrell Ajustado'[CANTIDAD_DIAS] <= 180, "Medio Plazo",  
6   "Largo Plazo")  
7
```

```
1 Margen Real = 'Anging Texrell Ajustado'[IMPORTE] - 'Anging Texrell Ajustado'[COSTE_TOTAL]
```

```
1 Contrato Deficitario =  
2 IF([MARGEN] < 0.40,  
3   "Pérdida",  
4   IF([MARGEN] < 0.45,  
5     "Margen Bajo",  
6     "OK")  
7   )  
8
```

```

1 Total Contratos en Pérdida =
2 CALCULATE(
3     COUNTROWS('Anging Texrell Ajustado'),
4     'Anging Texrell Ajustado'[Contrato Deficitario] = "Pérdida"
5 )
6
7

```

```

1 Dia de Semana = FORMAT([PERIODO], "dddd")

```

```

1 Mes = month('Anging Texrell Ajustado'[PERIODO])

```

```

1 Cuantrimestre = QUARTER([PERIODO])

```