

GUÍA
**TRANSFORMACIÓN
DIGITAL**

ADOPCIÓN DE INTELIGENCIA ARTIFICIAL



GUÍA TRANSFORMACIÓN DIGITAL
ADOPCIÓN DE INTELIGENCIA ARTIFICIAL

Presidencia Pro tempore 2023-2024,
Poder Judicial de la República Dominicana
Junio 2024

<https://consejjudicialcc.org/>

Contenido

1. OBJETIVO	5
2. OBJETIVOS ESPECÍFICOS	5
3. ALCANCE	5
INTRODUCCIÓN	5
4. DEFINICIONES	7
5. FACTORES CRITICO DE ÉXITO	10
1. Identificar casos de usos para AI	10
2. Evaluar la infraestructura tecnológica existente	10
3. Identificar casos de uso específicos	10
4. Desarrollar modelos de IA	11
5. Garantizar la transparencia y la equidad	11
6. Capacitar al personal	11
7. Monitorear el modelo	11
8. Mantener la seguridad y privacidad	11
6. ÉTICA	12
Principios Éticos y Directrices	12
Protección de Datos Personales y Privacidad	12
7. REVISIÓN Y ACTUALIZACIÓN	13
Revisiones Periódicas y Evaluaciones de Impacto	13

8. TÍTULO	13
9. ENLACE DE REFERENCIA.....	14
9. ANEXOS.....	14
9.1 Anexo 1: Ejemplo de Fases para los modelos de ML (Ejemplo únicamente para fines ilustrativo)	14
1. Fase de comprensión de los datos.....	14
1.1 Recolección de datos iniciales	14
1.2 Descripción de los datos	15
1.3 Exploración de datos	16
1.4 Verificación de la calidad de los datos.....	26
2. Fase de preparación de los datos.....	26
3. Fase de modelado	29
3.1 Selección de la técnica de modelado	29
3.2 Generación del plan de prueba.....	30
3.3 Construcción del Modelo.....	30
3.4 Evaluación del modelo.....	35
4. Fase de evaluación	36
4.1 Evaluación de los resultados.....	36
4.2 Proceso de revisión	37
4.3 Determinación de futuras fases.....	37
5. Fase de implementación.....	37
5.1 Plan de implementación	37

1. OBJETIVO

Establecer una guía para la transformación digital en el uso de Inteligencia Artificial en los Poderes Judiciales de Iberoamérica.

2. OBJETIVOS ESPECÍFICOS

- ◆ Ofrecer un marco conceptual y metodológico para la selección, el desarrollo, la implementación y la evaluación de soluciones de IA adaptadas a las necesidades y características del sistema judicial.
- ◆ Facilitar la capacitación, la formación y la sensibilización de los actores clave del sistema judicial en relación con el uso y el potencial de la IA en la justicia.
- ◆ Promover principios éticos, legales y regulatorios para garantizar un uso responsable, ético y legal de la IA en el ámbito judicial, respetando los derechos humanos, la equidad y la justicia social.
- ◆ Fomentar la colaboración, la participación y el compromiso de todas las partes interesadas en el proceso de transformación digital y adopción de la IA en el Poder Judicial.

3. ALCANCE

Es importante destacar que esta guía no pretende ser una norma o especificación técnica definitiva, sino más bien una orientación flexible y adaptable a las necesidades específicas de cada país. Se reconoce la diversidad legal, cultural y tecnológica de la región, y se alienta a los Poderes Judiciales a adaptar estos principios a sus contextos particulares, siempre respetando las leyes y normativas locales.

INTRODUCCIÓN

En un mundo cada vez más interconectado y tecnológicamente avanzado, la adaptación a las innovaciones es crucial para garantizar la eficiencia y la equidad en todos los ámbitos de la sociedad. En el contexto de los Poderes Judiciales de Iberoamérica, la transformación digital se presenta como una oportunidad sin precedentes para mejorar la administración de justicia y fortalecer la confianza en el sistema legal.

El objetivo de esta guía es establecer un marco integral para la implementación de la Inteligencia Artificial (IA) en los Poderes Judiciales de la región. A través de objetivos

específicos cuidadosamente delineados, esta propuesta busca ofrecer no solo una herramienta práctica, sino también una visión ética y legalmente sólida que garantice el uso responsable y transparente de la IA en la justicia. Esta guía no solo busca promover la adopción de tecnologías avanzadas, sino también asegurar que estas se alineen con los principios fundamentales de justicia, equidad y respeto a los derechos humanos.

Además, se enfatiza la importancia de la capacitación, la formación y la sensibilización de los actores clave del sistema judicial en relación con el uso y el potencial de la IA en la justicia. La comprensión y la confianza en estas tecnologías son fundamentales para su adopción exitosa y para garantizar que se utilicen de manera ética y efectiva.

La creación de una guía para incorporar Inteligencia Artificial (IA) en los sistemas transaccionales dentro de las organizaciones de justicia es crucial debido a la necesidad de garantizar que la implementación de estas tecnologías se realice de manera ética, transparente y eficiente. Dicha guía asegura que los sistemas de IA se desplieguen de forma que respeten los derechos fundamentales, contribuyan a la optimización de los procesos, mejoren la accesibilidad y la calidad del servicio judicial.

Al proporcionar un marco estructurado y detallado, la guía facilita la toma de decisiones informadas por parte de los responsables, promueve la estandarización de prácticas y ayuda a prevenir posibles riesgos asociados al uso de la IA, como el sesgo algorítmico y la violación de la privacidad, también permite que las organizaciones de justicia aprovechen las ventajas de la IA para ofrecer un servicio más justo, rápido y accesible a la ciudadanía, manteniendo al mismo tiempo la confianza pública en el sistema judicial.

Es muy importante resaltar que la Inteligencia Artificial (IA) no representa un concepto reciente en el ámbito tecnológico y científico; su estudio y desarrollo han estado presentes desde aproximadamente 1956, marcando el inicio de un campo que ha experimentado una evolución significativa a lo largo del tiempo.

Esta evolución ha avanzado desde las etapas iniciales del aprendizaje automático y el aprendizaje profundo, hasta llegar a la actual era de la inteligencia artificial generativa. El notable crecimiento y sofisticación de la IA se pueden atribuir principalmente a tres factores cruciales:

- ◆ La disponibilidad de grandes volúmenes de datos en la actualidad proporciona el recurso esencial para el entrenamiento de modelos de IA, permitiendo a estos sistemas aprender y mejorar con una precisión sin precedentes.
- ◆ La reducción en los costos del hardware y el software necesarios para implementar estas soluciones tecnológicas ha hecho que la IA sea más accesible y viable para una amplia gama de aplicaciones y sectores.

- ◆ La creciente necesidad de ofrecer servicios más eficientes y efectivos frente a las limitaciones de recursos con las que cuentan muchas instituciones. Este contexto ha impulsado la adopción de la IA como una herramienta fundamental para optimizar procesos, mejorar la toma de decisiones y, en última instancia, elevar la calidad de los servicios prestados a la sociedad.

Para aprovechar correctamente estas bondades tecnológicas la experiencia ha revelado que, para identificar eficazmente los casos de uso donde la IA puede ser implementada de manera beneficiosa, es fundamental contar con un conjunto de seis características mínimas. Estos criterios son esenciales para asegurar que la adopción de la IA aporte valor real y no se convierta en una solución costosa para problemas que podrían ser resueltos mediante automatización tradicional.

4. DEFINICIONES

Para comprender adecuadamente el papel y el potencial de la inteligencia artificial (IA) en el ámbito judicial, es esencial definir algunos conceptos clave:

Inteligencia Artificial (IA): Se refiere a la capacidad de las máquinas y sistemas informáticos para realizar tareas que normalmente requieren inteligencia humana, como el aprendizaje, la adaptación, la toma de decisiones y la resolución de problemas.

Aprendizaje Automático (Machine Learning):

Es una subdisciplina de la IA que se centra en el desarrollo de algoritmos y modelos computacionales que permiten a las máquinas aprender y mejorar a partir de datos, sin una programación explícita para cada tarea específica.

Análisis Predictivo:

Consiste en el uso de técnicas y modelos de IA para analizar datos históricos y actuales con el fin de predecir tendencias, patrones y resultados futuros en la gestión de casos, la toma de decisiones judiciales y otros aspectos relevantes del sistema judicial.

Automatización Robótica de Procesos (RPA):

Se refiere a la aplicación de la IA y la automatización para realizar tareas administrativas y rutinarias de manera eficiente y precisa, liberando tiempo y recursos humanos para actividades más complejas y estratégicas.

Principios Éticos y

Legales:

La adopción de la IA en el sistema judicial debe estar fundamentada en principios éticos y legales sólidos que garanticen un uso responsable, ético y equitativo de esta tecnología. Algunos de los principios fundamentales que deben guiar la implementación de la IA en el ámbito judicial incluyen:

- ◆ **Transparencia:** Garantizar que los algoritmos, modelos y decisiones de IA sean comprensibles, explicables y auditables para los usuarios y las partes involucradas en el proceso judicial.
- ◆ **Equidad y No Discriminación:** Asegurar que las soluciones de IA no perpetúen ni amplifiquen sesgos, prejuicios o discriminaciones existentes en el sistema judicial, promoviendo la equidad, la imparcialidad y el respeto a los derechos humanos y las libertades fundamentales.
- ◆ **Privacidad y Protección de Datos:** Respetar y proteger la privacidad, la confidencialidad y los datos personales de los ciudadanos, garantizando el cumplimiento de las leyes, normativas y estándares de protección de datos aplicables en el ámbito judicial.
- ◆ **Responsabilidad y Rendición de Cuentas:** Establecer mecanismos y procedimientos claros para atribuir responsabilidades, corregir errores, resolver disputas y garantizar la rendición de cuentas en relación con el uso y los resultados de la IA en el sistema judicial.

Analítica Avanzada y

Big Data:

Herramientas y soluciones de IA para el análisis y la interpretación de grandes volúmenes de datos judiciales, jurisprudencia, legislación y tendencias sociales para apoyar la toma de decisiones informadas y la formulación de políticas judiciales.

Chatbots y Asistentes

Virtuales:

Sistemas de IA conversacional para proporcionar información, orientación, asesoramiento y asistencia jurídica básica a los ciudadanos y los profesionales del derecho de manera rápida, accesible y personalizada.

Análisis Predictivo y

Modelado de Datos:

Algoritmos y modelos de IA para predecir resultados judiciales, evaluar riesgos, identificar patrones y tendencias, y optimizar la asignación de recursos en la gestión de casos y la administración de justicia.

Líder de proyecto de IA:

Define el alcance del proyecto, asegurar la alineación con los objetivos organizacionales, gestionar el equipo de proyecto, y servir como enlace entre los interesados y el equipo técnico.

Equipo técnico de IA

(desarrolladores, científicos de datos, ingenieros de IA):

Sus funciones son diseñar, desarrollar y desplegar modelos de IA, incluyendo la selección de algoritmos, el entrenamiento y validación de modelos, y la integración de soluciones de IA en los sistemas existentes.

Analistas de datos:

Deben preparar y analizar los datos para el entrenamiento de modelos de IA, asegurar la calidad de los datos, y realizar análisis exploratorios para identificar patrones y tendencias.

Expertos en ética y cumplimiento:

Deben evaluar las soluciones de IA desde una perspectiva ética y de cumplimiento legal, asegurar la protección de datos y la privacidad, y desarrollar políticas para el uso responsable de la IA.

Expertos en seguridad de la información:

Dentro sus funciones están implementar medidas de seguridad para proteger los datos y las soluciones de IA, realizar evaluaciones de riesgo, y asegurar la resiliencia de las soluciones frente a amenazas cibernéticas.

Usuarios Finales

(Personal de Justicia):

Deben participar en la fase de pruebas y validación de las soluciones de IA, proporcionar retroalimentación para la mejora de las herramientas, y adoptar las soluciones de IA en sus procesos de trabajo cotidianos.

Interesados

(Administradores de Justicia, Directivos):

Deben proporcionar dirección estratégica para el proyecto de IA, asegurar la disponibilidad de recursos, tomar decisiones críticas, y apoyar la implementación desde un nivel de liderazgo.

5. FACTORES CRITICO DE ÉXITO

Para comprender adecuadamente el papel y el potencial de la inteligencia artificial (IA) en el ámbito judicial, es esencial definir algunos conceptos clave:

1. Identificar casos de usos para AI

Evaluar las necesidades y desafíos: Antes de comenzar, es fundamental comprender las necesidades específicas del sistema judicial y los desafíos que enfrenta.

Involucrar a todas las partes interesadas: Es importante involucrar a jueces, abogados, funcionarios del tribunal, expertos en tecnología y otros actores relevantes desde el principio. Organiza reuniones, talleres y sesiones de consulta para recopilar sus opiniones y sugerencias.

Formar un equipo multidisciplinario: Crea un equipo que incluya expertos en derecho, tecnología de la información, ciencia de datos y ética. Este equipo será responsable de diseñar e implementar soluciones de IA de manera efectiva y ética.

2. Evaluar la infraestructura tecnológica existente

Antes de implementar IA, es importante evaluar la infraestructura tecnológica existente en el poder judicial. Cuáles son las capacidades actuales en términos de hardware, software y conectividad

3. Identificar casos de uso específicos

Identificar casos específicos donde la IA pueda generar valor añadido, tales como la predicción de resultados judiciales, la gestión eficiente de casos, la automatización de tareas rutinarias y el análisis de patrones en datos judiciales. A continuación:

- a. Elegir el tipo de lenguaje para soluciones de inteligencia artificial o el framework
Recopilar y preparar datos
- b. Elegir el tipo de desarrollo

La IA depende en gran medida de los datos de alta calidad para funcionar correctamente. Asegúrate de recopilar y preparar datos judiciales relevantes de manera ética y legalmente compatible.

4. Desarrollar modelos de IA

Utiliza técnicas de aprendizaje automático y análisis de datos para desarrollar modelos de IA que se adapten a los casos de uso previamente identificados. Verifica y valida estos modelos utilizando conjuntos de datos pertinentes. A continuación:

- ◆ Entrenar el modelo desde cero con los datos recopilados y preparados.
- ◆ Integrar el modelo en los sistemas transaccionales existentes.
- ◆ Incorporar el modelo mediante una API para una interacción fluida.
- ◆ Almacenar los resultados obtenidos en la base de datos correspondiente.
- ◆ Establecer un proceso de reentrenamiento periódico para mantener la eficacia del modelo.

5. Garantizar la transparencia y la equidad

Es fundamental que los sistemas de IA en el poder judicial sean transparentes y equitativos. Esto implica explicar cómo se toman las decisiones y garantizar que no haya sesgos injustos en los algoritmos.

6. Capacitar al personal

Proporciona capacitación adecuada a jueces, abogados y personal del tribunal sobre cómo utilizar y comprender las herramientas de IA. Esto ayudará a garantizar una adopción exitosa y una comprensión sólida de las implicaciones éticas y legales.

7. Monitorear el modelo

Evaluar y ajustar: Realiza evaluaciones periódicas para medir el impacto de la IA en el sistema judicial y realiza ajustes según sea necesario. Esto garantizará que las soluciones de IA sigan siendo efectivas y relevantes a lo largo del tiempo.

8. Mantener la seguridad y privacidad

Asegúrate de cumplir con las normativas de seguridad y privacidad de datos al implementar soluciones de IA en el poder judicial. Proteger la integridad y la confidencialidad de la información es fundamental.

6. ÉTICA

Principios Éticos y Directrices

La implementación de inteligencia artificial (IA) en los Poderes Judiciales, debe estar fundamentada en principios éticos sólidos que garanticen un uso responsable, transparente, equitativo y ético de esta tecnología. Algunos de los principios éticos y directrices que deben guiar la adopción de la IA en el ámbito judicial incluyen:

- ◆ **Transparencia y Explicabilidad:** Garantizar que los algoritmos, modelos y decisiones de IA sean transparentes, explicables y comprensibles para los usuarios, las partes involucradas y el público en general, facilitando la rendición de cuentas y la confianza en el sistema judicial.
- ◆ **Equidad y No Discriminación:** Asegurar que las soluciones de IA no perpetúen ni amplifiquen sesgos, prejuicios o discriminaciones existentes en el sistema judicial, promoviendo la equidad, la imparcialidad y el respeto a los derechos humanos y las libertades fundamentales de todos los ciudadanos.
- ◆ **Integridad y Precisión:** Garantizar la integridad, la precisión y la fiabilidad de los datos, algoritmos y modelos utilizados en las soluciones de IA, minimizando el riesgo de errores, sesgos y decisiones incorrectas que puedan afectar la calidad y la justicia de las decisiones judiciales.
- ◆ **Privacidad y Confidencialidad:** Respetar y proteger la privacidad, la confidencialidad y los datos personales de los ciudadanos en conformidad con las leyes, normativas y estándares de protección de datos aplicables en el ámbito judicial.
- ◆ **Responsabilidad y Rendición de Cuentas:** Establecer mecanismos y procedimientos claros para atribuir responsabilidades, corregir errores, resolver disputas y garantizar la rendición de cuentas en relación con el diseño, desarrollo, implementación y uso de las soluciones de IA en el sistema judicial.

Protección de Datos Personales y Privacidad

La protección de datos personales y la privacidad son aspectos críticos que deben ser cuidadosamente gestionados y asegurados en el desarrollo, implementación y operación de soluciones de IA en los Poderes Judiciales. Para ello, es fundamental:

- ◆ **Principio de Minimización de Datos:** Recopilar, procesar y almacenar únicamente los datos personales necesarios y relevantes para los fines específicos y legítimos de las soluciones de IA en el ámbito judicial, minimizando el riesgo de recopilación y tratamiento excesivo o innecesario de datos.

- ◆ **Medidas de Seguridad y Confidencialidad:** Implementar medidas técnicas y organizativas adecuadas para proteger los datos personales contra el acceso no autorizado, el uso indebido, la divulgación, la alteración o la destrucción, asegurando la integridad, la confidencialidad y la disponibilidad de los datos en todo momento.

7. REVISIÓN Y ACTUALIZACIÓN

Revisiones Periódicas y Evaluaciones de Impacto

Para asegurar la efectividad, la relevancia y la integridad de las soluciones de inteligencia artificial (IA) implementadas en el sistema judicial, es fundamental llevar a cabo revisiones periódicas y evaluaciones de impacto. Estas revisiones y evaluaciones deben realizarse de manera regular y sistemática para:

- ◆ **Monitorear el Desempeño y la Eficiencia:** Evaluar el rendimiento, la precisión, la eficiencia y la confiabilidad de los sistemas de IA en la administración de justicia, identificando áreas de mejora, optimización y refinamiento.
- ◆ **Analizar el Impacto Ético y Social:** Examinar el impacto ético, social, legal y cultural de las soluciones de IA en los usuarios, las partes involucradas, los derechos humanos y las libertades fundamentales, así como en la equidad, la inclusión y la no discriminación en el sistema judicial.
- ◆ **Verificar la Conformidad Legal y Regulatoria:** Asegurar el cumplimiento continuo con el marco legal, normativo y ético aplicable, identificando posibles riesgos, vulnerabilidades y áreas de no conformidad que requieran atención y acción correctiva.
- ◆ **Recopilar Feedback y Mejorar la Participación:** Obtener retroalimentación, opiniones, experiencias y necesidades de los usuarios, los stakeholders y la comunidad en general para mejorar la usabilidad, la accesibilidad y la adaptabilidad de las soluciones de IA a las demandas y expectativas del sistema judicial.

8. TÍTULO

- 3.1 Describir el protocolo de actuación, listando las acciones específicas que las personas deben seguir
- 4.1 Listar los roles involucrados en el protocolo y sus principales responsabilidades

9. ENLACE DE REFERENCIA

9. ANEXOS

9.1 Anexo 1: Ejemplo de Fases para los modelos de ML (Ejemplo únicamente para fines ilustrativo)

El ejemplo proporcionado mediante la adaptación de la metodología CRISP-ML para la implementación y evaluación de soluciones de Inteligencia Artificial (IA) en organizaciones de justicia sirve exclusivamente con fines demostrativos. Su objetivo principal es ilustrar un enfoque estructurado para incorporar prácticas éticas y consideraciones legales en el desarrollo y aplicación de tecnologías de IA. Este marco se ofrece como una guía para facilitar la comprensión y el enfoque en aspectos críticos tales como la transparencia, equidad, y privacidad, que son fundamentales en el ámbito de la justicia.

Es importante subrayar que este ejemplo no tiene la intención de restringir o limitar la capacidad creativa y la innovación dentro de las organizaciones de justicia. Al contrario, se alienta a cada organización a adaptar, modificar y expandir este marco según sus propias necesidades, objetivos específicos, y contextos operativos. La adaptabilidad y la personalización son cruciales, ya que permiten a las organizaciones explorar soluciones de IA que no solo cumplan con estándares éticos y legales, sino que también respondan de manera efectiva a sus desafíos únicos y aprovechen al máximo el potencial de la tecnología para mejorar los servicios de justicia.

La creatividad y la innovación son componentes esenciales en el proceso de implementación de la IA, permitiendo descubrir nuevas formas de resolver problemas, optimizar procesos y ofrecer servicios más eficientes y accesibles. Por lo tanto, este ejemplo debe ser visto como un punto de partida que inspira la exploración y el desarrollo de soluciones innovadoras, siempre con un compromiso firme con los principios de justicia, equidad y respeto por la privacidad de los individuos. Las organizaciones de justicia están invitadas a ir más allá de las recomendaciones básicas, experimentando y adaptando tecnologías de IA de maneras que enriquezcan su misión y amplíen sus capacidades para servir a la sociedad.

Las posibles fases son:

1. Fase de comprensión de los datos

1.1 Recolección de datos iniciales

El Poder Judicial tiene dos orígenes de datos posibles para estas soluciones se puede utilizar el sistema transaccional “Sistema integrado de gestión administrativa del Poder Judicial” o

el datawarehouse administrativo, al final se elige el data, porque esta información tiene un proceso de limpieza durante el aplanamiento de los datos, esto aumentará el porcentajes de la calidad de los mismos, en especialmente porque los reportes descriptivos de esta información son utilizados por los Departamento de Proveduría y Financiero Contable esto significa que constantemente son verificados, validados y utilizados para ejecutar diferentes procesos de esos departamentos.

1.2 Descripción de los datos

Se cuentan con 24035 registros actuales de pedidos con 21 variables que inician durante el año 2015 hasta junio del 2019, estos datos ya tienen fecha de aplicación y su disponible es igual a 0, los datos que se utilizaran son:

BK_Periodo:	Periodo de ejecución del documento
BK_Num_Pedido:	Llave del negocio
TC_Des_Tipo_Grupo_Programa:	Tipo de grupo de programa presupuestario de donde se rebajan los fondos
BK_Cod_Subpartida:	Se refiere a la subpartida presupuestaria que da origen a la compra
TC_Des_Partida:	Se refiere a la partida presupuestaria que da origen a la compra
TC_Des_Fte_Financ:	Se refiere a la fuente de financiamiento que da origen a la compra
TC_Des_Rubro:	Cuando es de tipo gasto fijo, tiene un rubro, puede ser servicios, contratos, entre otros
TC_Des_Tipo_Pedido:	Puede ser ordinario o complementario
TC_Des_Clase_Req:	Se refiere a la clase de la requisición con la que se inicia la contratación o el tramite
TL_Ind_Consultoria:	Indica si proviene de una contratación o no.
TL_Ind_Proviene_Adj:	Indica si proviene de una contratación o no.
TL_Ind_CND:	Indica si es un compromiso no devengado o no.
BK_Cod_Estado_Documento:	Estado del documento presupuestario
TC_Cod_Ofi_SIGMA:	Oficina que origina la compra

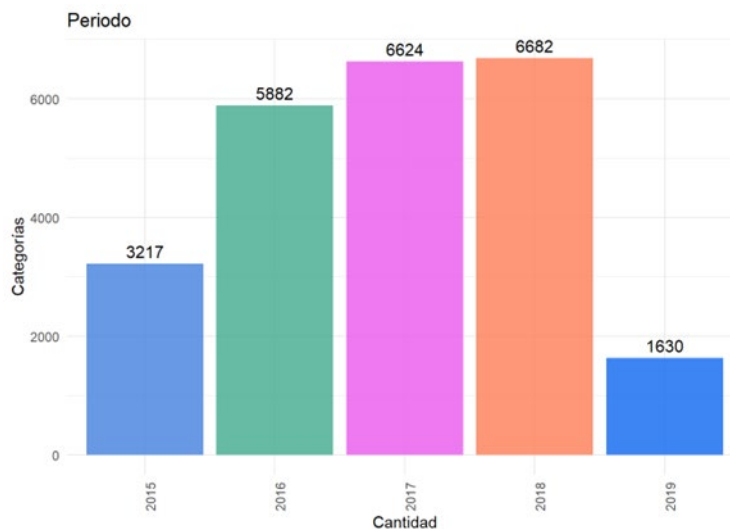
TC_Des_Area_Tramita:	Se refiera al área que ejecuta el proceso de ejecución puede ser compra menor, compra directa o licitaciones
TC_Des_Tipo_Gasto:	Puede ser gasto fijo o variable, depende del origen de los recursos.
TC_Des_Tipo_Moneda:	Tipo de moneda del pedido, puede ser dólar, colones, libra esterlina, etc.
TF_Creacion:	Fecha de creación del pedido.
TC_Des_Medio_Pago:	Medio de pago utilizado para cancelar el pedido.
TF_Aplicacion:	Fecha de creación de la última factura asociada.
TN_Mon_Pedido:	Monto en colones del pedido presupuestario.

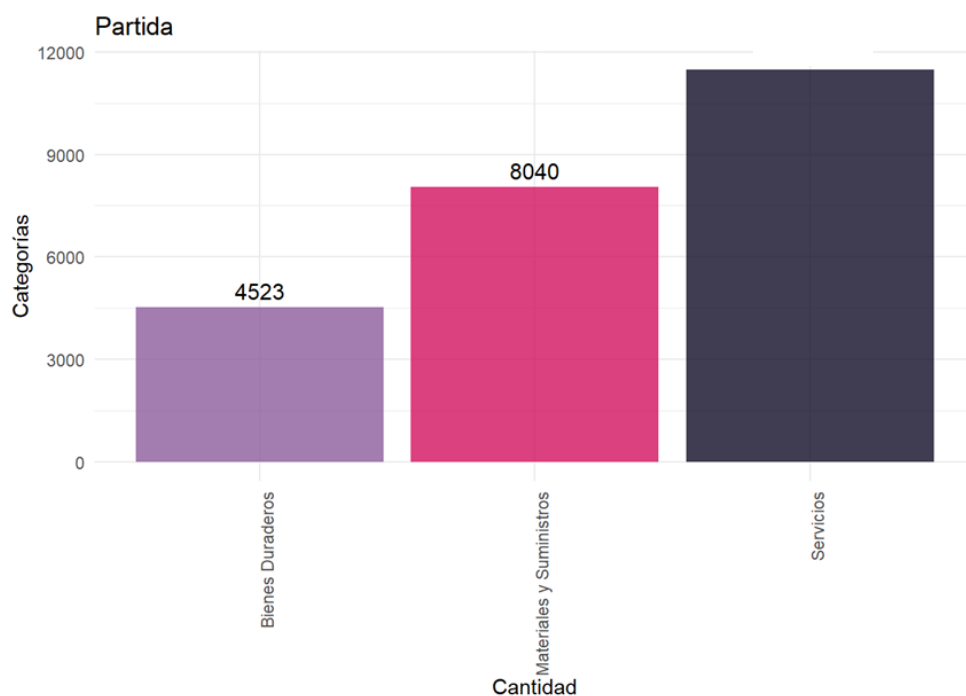
Estos serían los datos que nos van a servir para entrenar nuestros modelos, para usar los modelos de datos en la predicción, vamos a utilizar todos aquellos pedidos que no tienen fecha de aplicación y su disponible es diferente a 0.

1.3 Exploración de datos


Durante la exploración de datos, se identifica que la carga esta reconociendo como variables numéricas los campos “BK_Periodo”, “BK_Cod_Subpartida”, “TC_Cod_Ofi_SIGMA”, “TL_Ind_Consultoria”, “TL_Ind_Proviene_Adj” y “TL_Ind_CND” por esta razón se modifican a categóricas.

Para la variable del BK_Periodo se logra identificar que el año 2015 presenta una cantidad menor según el comportamiento de los demás años.






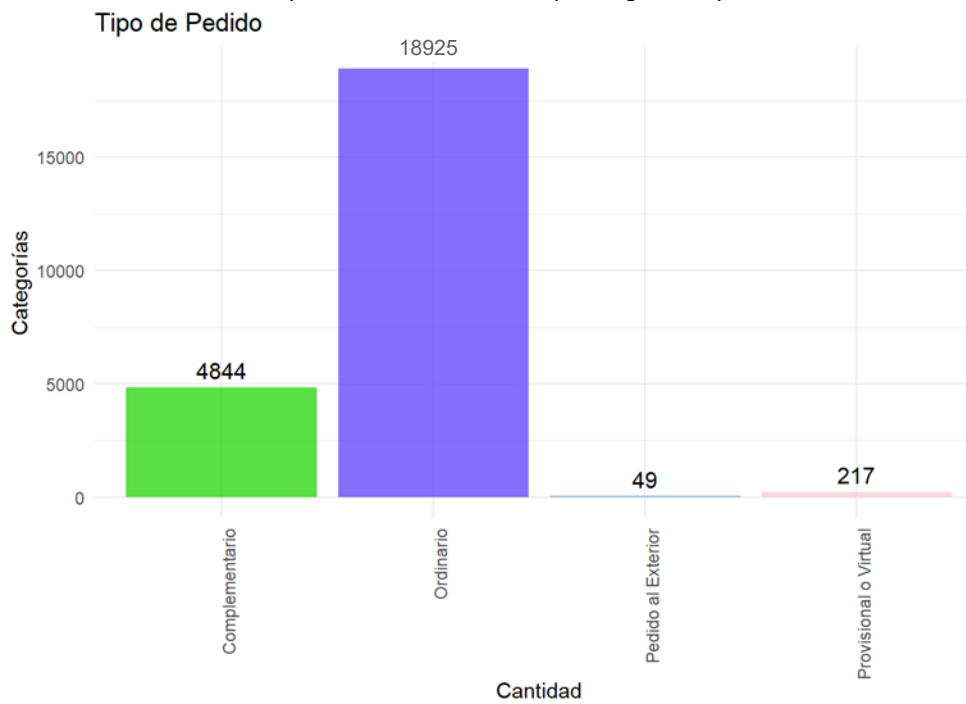
Con la variable TC_Des_Fte_Financ no se identifique ningún comportamiento extraño.




Con la variable TC_Des_Rubro se logra apreciar que existen más de 18 mil documentos con rubro igual a Desconocido.



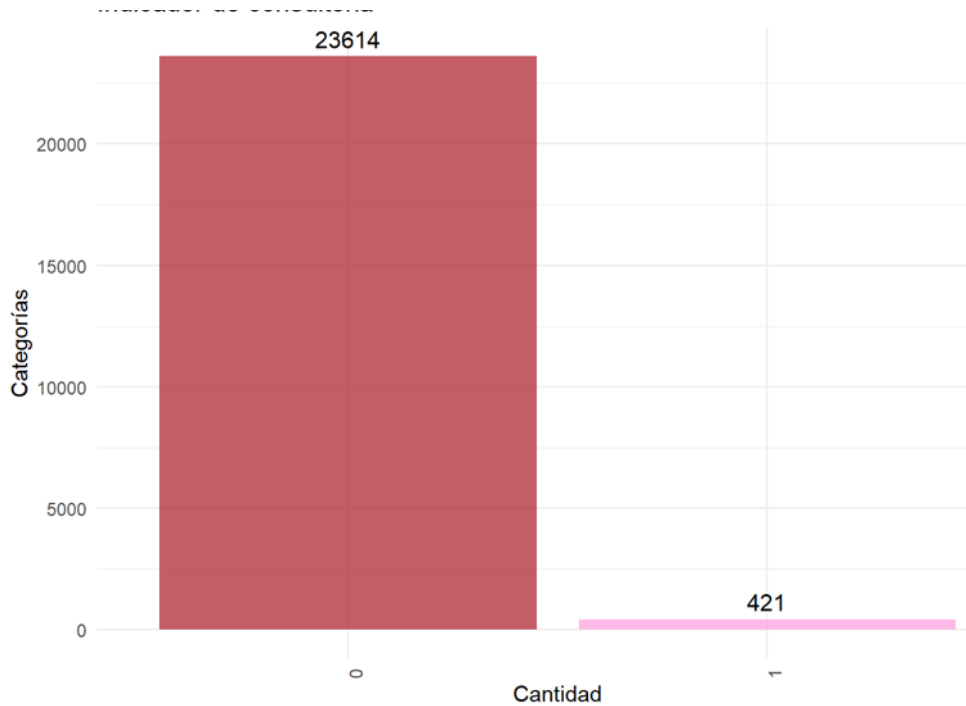
Con la variable TC_Des_Tipo_Pedido no se identifique ningún comportamiento extraño.



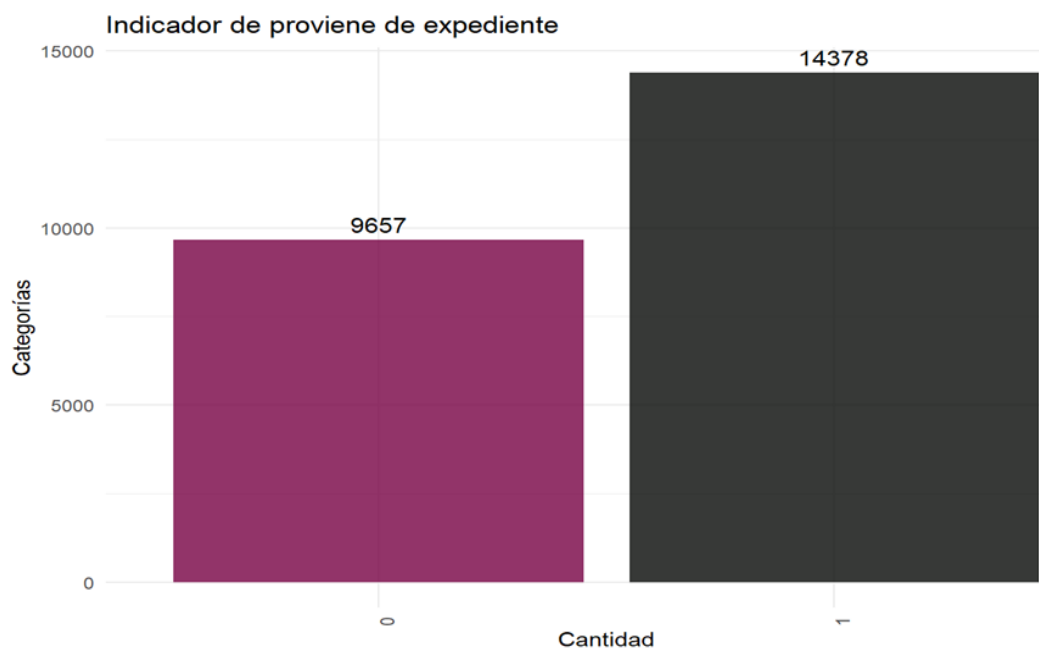
Con la variable TC_Des_Clase_Req no se identifique ningún comportamiento extraño.



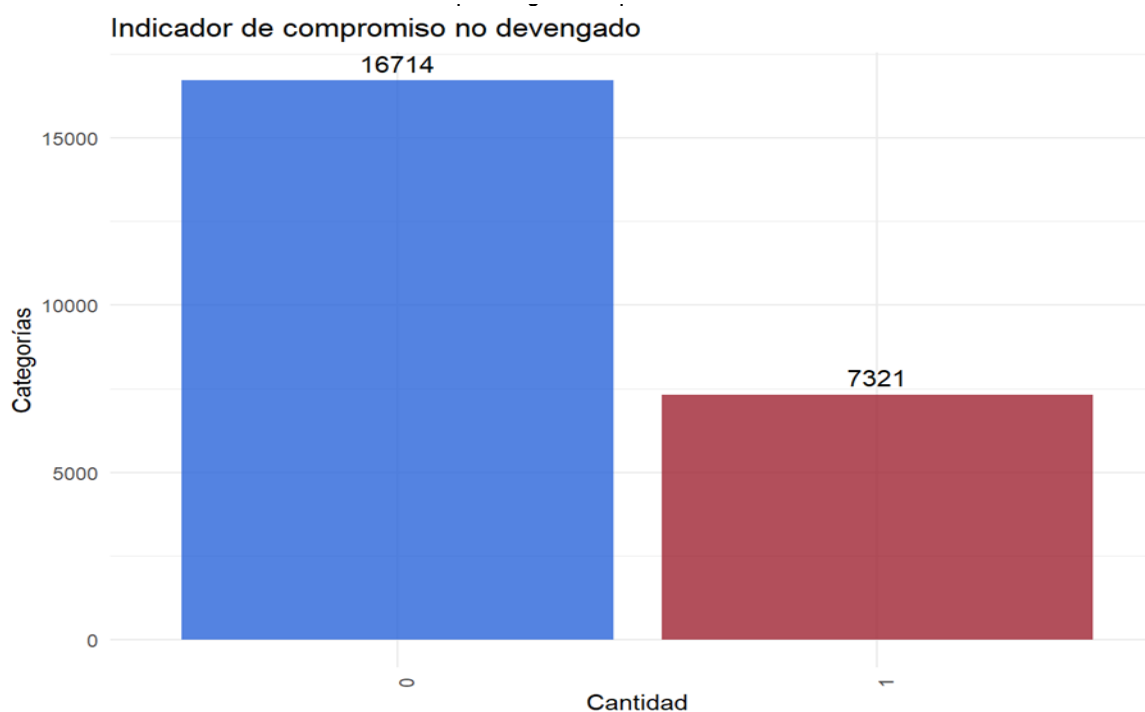
Con la variable TL_Ind_Consultoria no se identifique ningún comportamiento extraño.



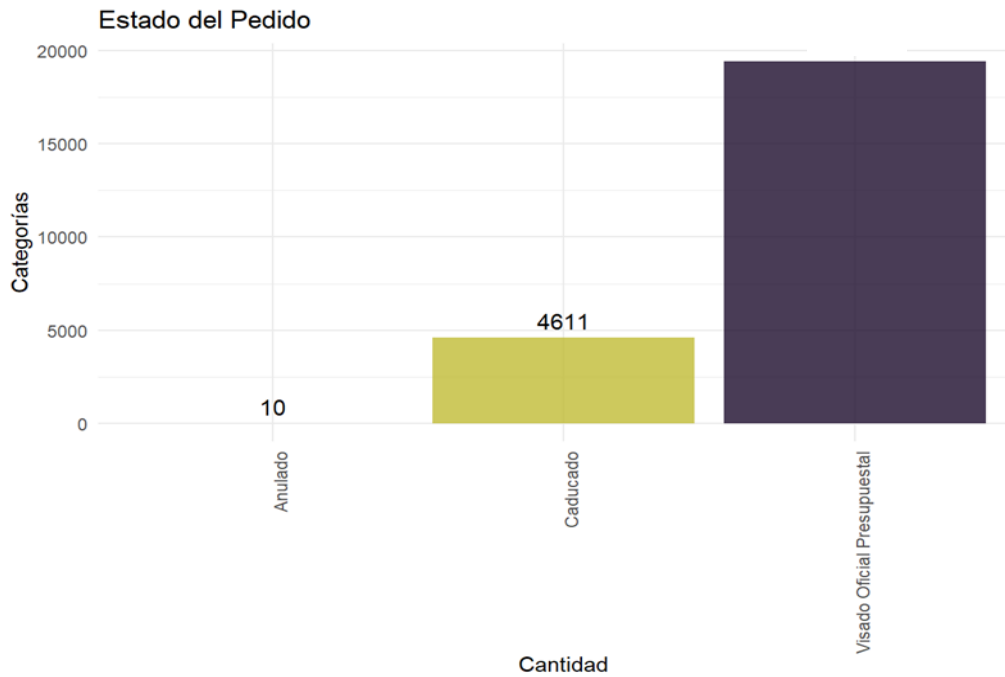
Con la variable TL_Ind_Proviene_Adj no se identifique ningún comportamiento extraño.




Con la variable TL_Ind_CND no se identifique ningún comportamiento extraño.



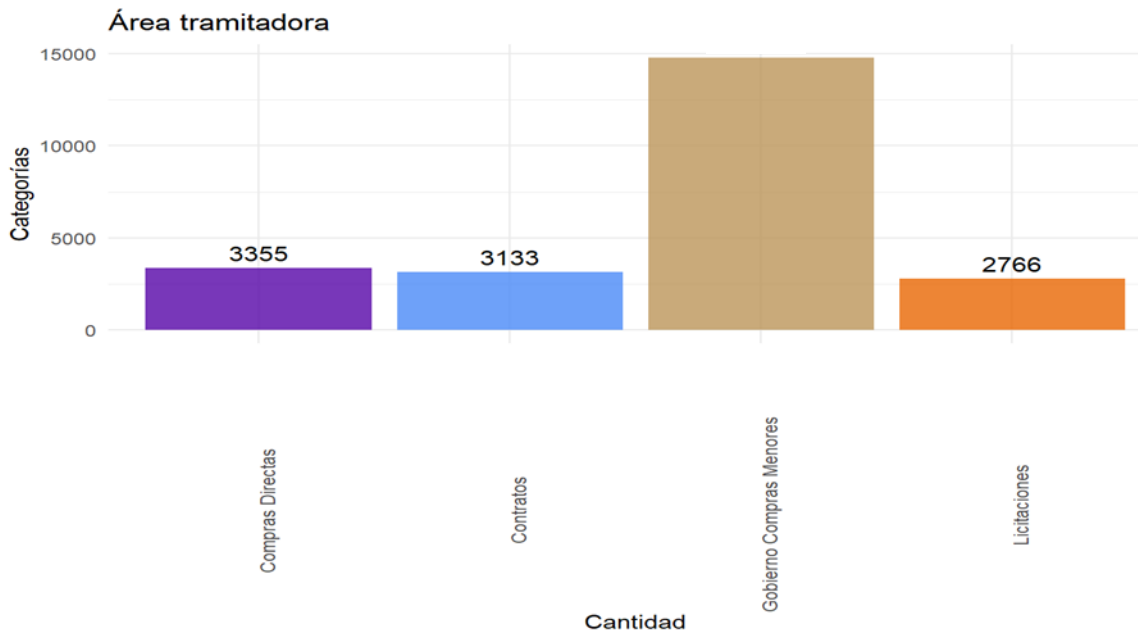
Con la variable BK_Cod_Estado_Documento se identifican 10 pedidos con estado anulado.



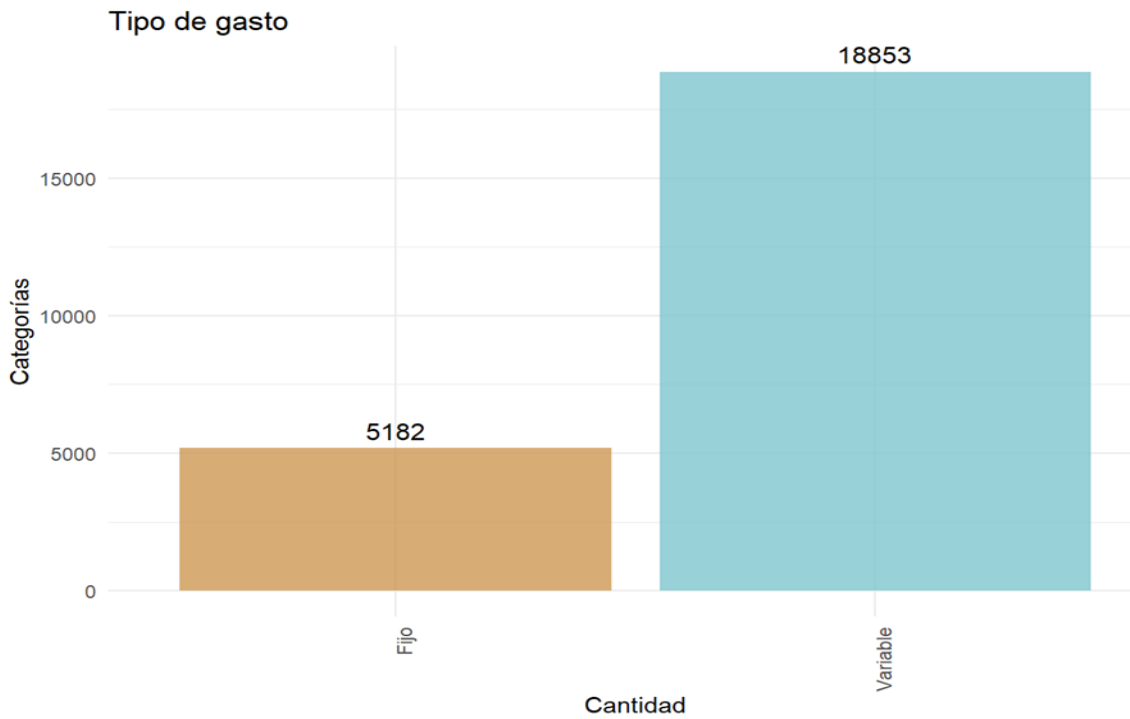
Con la variable TC_Cod_Ofi_SIGMA no se identifique ningún comportamiento extraño.



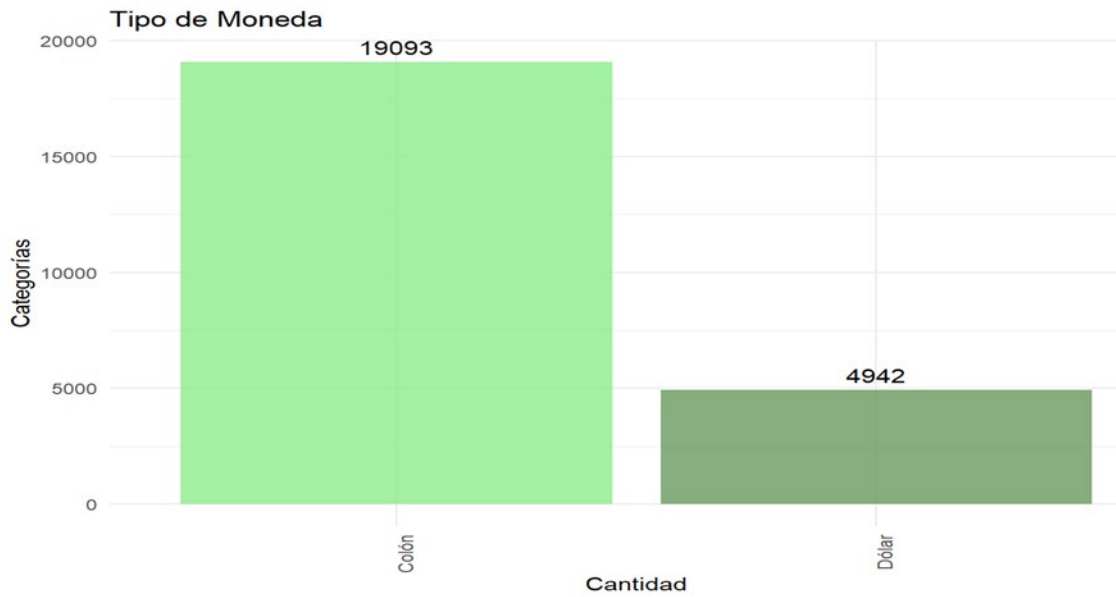
Con la variable TC_Des_Area_Tramita no se identifique ningún comportamiento extraño.



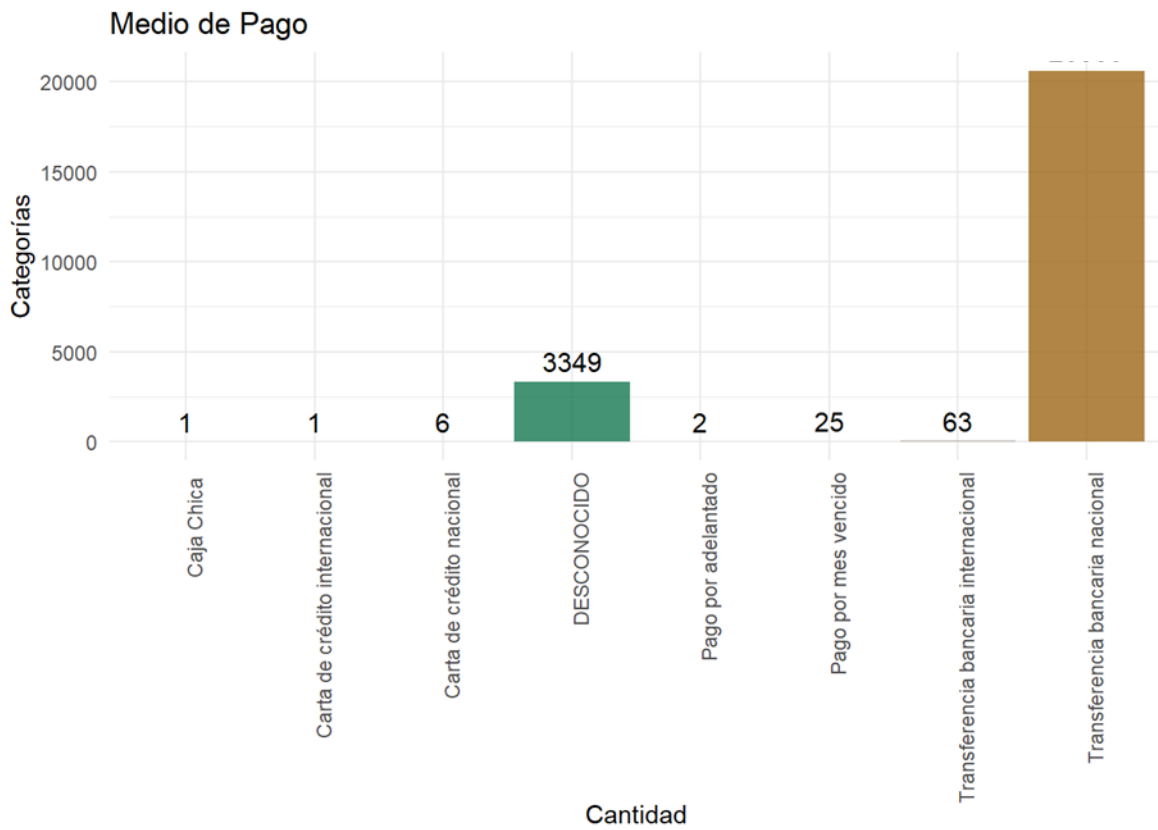
Con la variable TC_Des_Tipo_Gasto no se identifique ningún comportamiento extraño.




Con la variable TC_Des_Tipo_Moneda no se identifique ningún comportamiento extraño.



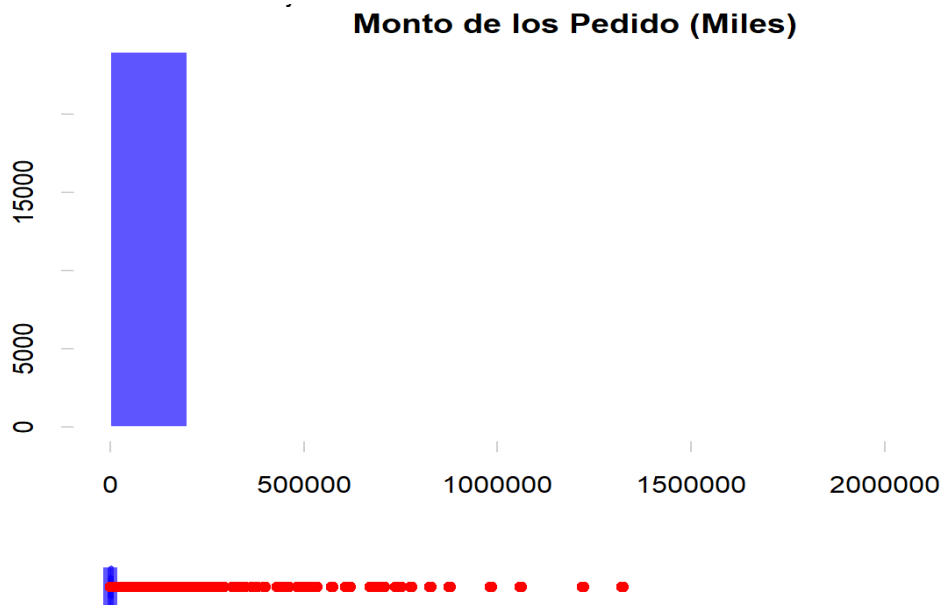
Con la variable TC_Des_Medio_Pago se identifique 3349 pedidos con medio de pago igual a desconocido.



En la variable TN_Mon_Pedido se logra apreciar una asimetría positiva, indica que hacia la derecha tenemos más valores distintos y que moda y mediana son menores al promedio.



Se identifican con montos muy elevados.



Las variables "TF_Creacion" y "TF_Aplicacion" por ser fechas se utilizarán en procesos preparación de datos, en este punto únicamente se validó que no tuvieran valores nulos (1900-01-01).

1.4 Verificación de la calidad de los datos

Con el análisis exploratorio realizado se obtienen los siguientes hallazgos y conclusiones:

1. Con la variable BK_Periodo para el año 2015 se identificó una cantidad menor, investigando fue un periodo de paralelo donde el sistema no estuvo en totalidad en producción, por esta razón se utilizarán los datos a partir del 2016. Además, es normal que a junio del 2019 haya pocos datos porque la mayor cancelación de pedidos se da durante el segundo semestre del año.
2. Con la variable TC_Des_Rubro se identificaron muchos casos con valor desconocido, investigando nos explican que los pedidos con TC_Des_Tipo_Gasto igual a Variable no tienen rubro asociado, por esta razón la cantidad de desconocidos en el rubro es un valor normal, por esta razón este hallazgo no afecta la muestra de datos.
3. Con la variable BK_Cod_Estado_Documento hay 10 pedidos anulados, al investigar nos comunican que esto es una grave inconsistencias, por esta razón se excluyen de la muestra.
4. Con la variable TC_Des_Medio_Pago hay 3349 pedidos con medio de pago desconocido, al investigar nos comunican que esto es una grave inconsistencias, por esta razón se excluyen de la muestra.
5. Con la variable de TN_Mon_Pedido se identificaron montos muy elevados sin embargo son contratos que se pagan en más de un periodo, por esta razón se deciden dejar en la muestra.
6. Se excluye el campo BK_Num_Pedido porque al ser llave de negocio no aporta valor durante el análisis de los datos y puede llegar a generar un sesgo enorme.

2. Fase de preparación de los datos

2.1 Selección y limpieza de datos

Como resultado de aplicar las mejoras al conjunto de datos descritos en “Fase de comprensión de los datos” se cuentan con un conjunto de datos de 17660 registros actuales de pedidos con 20 variables que inician en el año 2016 hasta junio del 2019, estos datos ya tienen fecha de aplicación y su disponible es igual a 0.

2.2 Estructuración e Integración de los datos

Del conjunto de datos actual se crean a partir de la variable “TF_Creacion” los campos “diaCreacion”, “mesCreacion”, “trimestreCreacion”,

“cuatrimestreCreacion”, “semestreCreacion” y “yearCreacion”, con el propósito de ver si logramos identificar algún tipo de correlación entre esas variables.

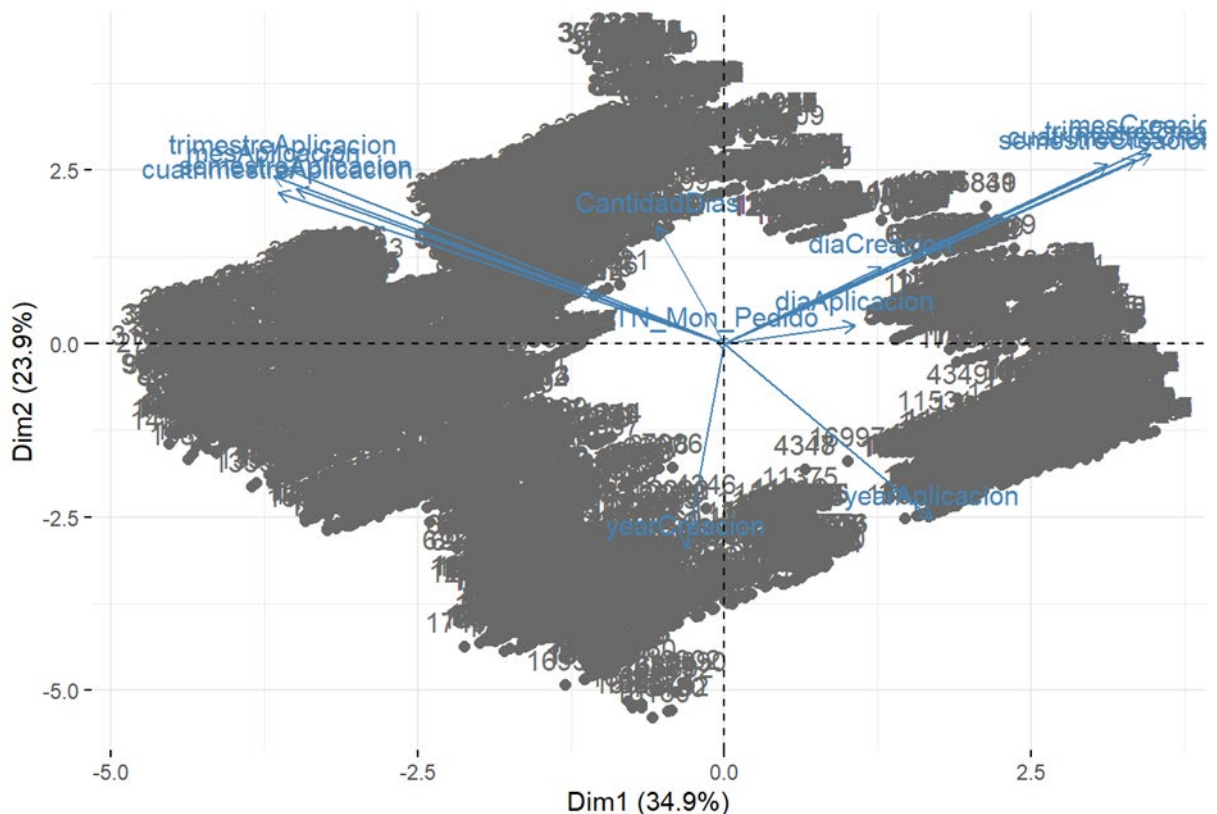
Además, se crean a partir de la variable “TF_Aplicacion” los campos “diaAplicacion”, “mesAplicacion”, “trimestreAplicacion”, “cuatrimestreAplicacion”, “semestreAplicacion” y “yearAplicacion”, con el propósito de ver si logramos identificar algún tipo de correlación entre esas variables.

Finalmente se crea la variable CantidadDias que representa la cantidad de días entre la fecha de creación y la fecha de aplicación de un pedido. Esta es la variable para predecir.

Con esto el conjunto de datos tiene 17660 registros actuales de pedidos con 31 variables que inician en el año 2016 hasta junio del 2019, estos datos ya tienen fecha de aplicación y su disponible es igual a 0.

2.3 Formateo de los datos

El nuevo conjunto de datos claramente nos brinda más datos para analizar, se realiza un análisis de componentes principales y vemos que se representa en total del 64,8 % de datos representados.



- ◆ Bosques aleatorios
- ◆ Potenciación (Gaussian, laplace, tdist)
- ◆ K vecinos más cercanos (optimal, rectangular, triangular, epanechnikov, biweight, triweight, cos, inv, Gaussian)
- ◆ Soporte Vectorial (radial, linear, polynomial, sigmoid)
- ◆ Reducción de dimensiones (ACP, MPC)

3.2 Generación del plan de prueba

El procedimiento para valorar el error consiste en medir los siguientes valores:

- ◆ Raíz de la desviación cuadrática media: Valor principal considerado en la selección del modelo, por su independencia de escala.
- ◆ Error absoluto medio: Segundo valor tomado en cuenta para identificar que tan lejos esta del cero el promedio.
- ◆ Error relativo: Tercer valor considerado, este porcentaje es un indicador de la calidad utilizado
- ◆ Correlación: Valoramos la correlación el valor real y la predicción
- ◆ Porcentajes de errores absolutos hacia arriba: Porcentaje de lo fallado hacia arriba

Estas mediciones se considerarán para cada modelo construido.

3.3 Construcción del Modelo

A continuación, se detalla la creación y configuración de cada uno de los modelos:

1. Regresión lineal: Se implementa de forma normal con los datos con el conjunto de datos final.

```
modelo.r1 <- lm(CantidadDias~., data = datos.aprendizaje)
#modelo.r1
prediccion.r1 <- predict(modelo.r1, datos.prueba)
#prediccion.r1
```

2. Regresión Penalizada con algoritmo Ridge: Se implementa con el conjunto de datos final utilizando el mejor Lambda de forma automática.

```
x <- model.matrix(CantidadDias~., datos.aprendizaje)[, -1]
y <- datos.aprendizaje[, 'CantidadDias']
modelo.rlr.ridge <- glmnet(x, y, standardize = TRUE, alpha = 0)

prueba <- model.matrix(CantidadDias~., datos.prueba)[, -1]
cv.glm.ridge <- cv.glmnet(x, y, standardize = TRUE, alpha = 0)
prediccion.rlr.ridge <- predict(modelo.rlr.ridge, newx = prueba, s = cv.glm.ridge$lambda.min, exact = TRUE, x = x,
```

3. Regresión Penalizada con algoritmo Ridge: Se implementa con el conjunto de datos final utilizando el mejor Lambda de forma automática.

```
modelo.rlr.lasso <- glmnet(x, y, standardize = TRUE, alpha = 1)
cv.glm.lasso <- cv.glmnet(x, y, standardize = TRUE, alpha = 1)
prediccion.rlr.lasso <- predict(modelo.rlr.lasso, newx = prueba, s = cv.glm.lasso$lambda.min, exact = TRUE, x = x)
resultado <- general_indices(datos.prueba[, 'CantidadDias'], prediccion.rlr.lasso)
```

4. Árboles de regresión: Se implementa con el conjunto de datos final con un mínimo de dos para dividir el nodo y se estuvo probando con el valor de la profundidad máxima hasta llegar al valor de 30 donde se obtuvieron los mejores resultados.

```
modelo.dt <- rpart(CantidadDias~., data = datos.aprendizaje, control = rpart.control(minsplit = 2, maxdepth = 30))
prediccion.dt <- predict(modelo.dt, datos.prueba)
```

5. Bosques aleatorios: Se implementa con el conjunto de datos final con valor de dos en el número de variables y se estuvo probando con el valor de la cantidad de árboles hasta llegar al valor de 30 donde se obtuvieron los mejores resultados

```
modelo.rf <- randomForest(CantidadDias~., data = datos.aprendizaje, importance = TRUE, ntree = 30, mtry = 10)
prediccion.rf <- predict(modelo.rf, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

6. Potenciación con algoritmo gaussian: Se implementa con el conjunto de datos final con valor de 0.01 en el ritmo de aprendizaje y se estuvo probando con el valor de la cantidad de árboles hasta llegar al valor de 30 donde se obtuvieron los mejores resultados

```
modelo.boosting.gaussian <- gbm(CantidadDias~., data = datos.aprendizaje, distribution = 'gaussian', n.trees = 30, shrinkage = 0.01, n.minobsinnode = 10, bag.fraction = 0.5)
prediccion.boosting.gaussian <- predict(modelo.boosting.gaussian, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')], n.trees = 30)
```

7. Potenciación con algoritmo laplace: Se implementa con el conjunto de datos final con valor de 0.01 en el ritmo de aprendizaje y se estuvo probando con el valor de la cantidad de árboles hasta llegar al valor de 30 donde se obtuvieron

```
modelo.boosting.laplace <- gbm(CantidadDias~ ., data = datos.aprendizaje, distribution = 'laplace', n.trees = 30, shrinkage = 0.01, n.minobsinnode = 10, bag.fraction = 0.5)
prediccion.boosting.laplace <- predict(modelo.boosting.laplace, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')], n.trees = 20)
```

8. Potenciación con algoritmo tdist: Se implementa con el conjunto de datos final con valor de 0.01 en el ritmo de aprendizaje y se estuvo probando con el valor de la cantidad de árboles hasta llegar al valor de 30 donde se obtuvieron los mejores resultados.

```
modelo.boosting.tdist <- gbm(CantidadDias~ ., data = datos.aprendizaje, distribution = 'tdist', n.trees = 30, shrinkage = 0.01, n.minobsinnode = 10, bag.fraction = 0.5)
prediccion.boosting.tdist <- predict(modelo.boosting.tdist, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')], n.trees = 20)
```

9. K Vecinos más cercanos con el algoritmo optimal: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.optimal <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorKmax, kernel = 'optimal')
prediccion.knn.optimal <- predict(modelo.knn.optimal, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

10. K Vecinos más cercanos con el algoritmo rectangular: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.rectangular <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorKmax, kernel = 'rectangular')
prediccion.knn.rectangular <- predict(modelo.knn.rectangular, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

11. K Vecinos más cercanos con el algoritmo triangular: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.triangular <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorKmax, kernel = 'triangular')
prediccion.knn.triangular <- predict(modelo.knn.triangular, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

12. K Vecinos más cercanos con el algoritmo epanechnikov: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.epanechnikov <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorkmax, kernel =
'epanechnikov')
prediccion.knn.epanechnikov <- predict(modelo.knn.epanechnikov, datos.prueba[,-which(colnames(datos.prueba) ==
'CantidadDias')])
```

13. K Vecinos más cercanos con el algoritmo biweight: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.biweight <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorkmax, kernel = 'biweight')
prediccion.knn.biweight <- predict(modelo.knn.biweight, datos.prueba[,-which(colnames(datos.prueba) == 'CantidadDias')])
```

14. K Vecinos más cercanos con el algoritmo triweight: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.triweight <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorkmax, kernel =
'triweight')
prediccion.knn.triweight <- predict(modelo.knn.triweight, datos.prueba[,-which(colnames(datos.prueba) == 'CantidadDias')])
```

15. K Vecinos más cercanos con el algoritmo cos: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.triweight <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorkmax, kernel =
'triweight')
prediccion.knn.triweight <- predict(modelo.knn.triweight, datos.prueba[,-which(colnames(datos.prueba) == 'CantidadDias')])
```

16. K Vecinos más cercanos con el algoritmo inv: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.inv <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorkmax, kernel = 'inv')
prediccion.knn.inv <- predict(modelo.knn.inv, datos.prueba[,-which(colnames(datos.prueba) == 'CantidadDias')])
```

17. K Vecinos más cercanos con el algoritmo gaussian: Se implementa con los datos con el conjunto de datos final con valor de dos en la distancia q y se calculó la raíz cuadrada de la cantidad de filas del conjunto de datos redondeado, esto para ser usado como valor de k máximo. Esto si impacto mucho la ejecución del modelo.

```
modelo.knn.gaussian <- train.kknn(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kmax=valorKmax, kernel = 'gaussian')
prediccion.knn.gaussian <- predict(modelo.knn.gaussian, datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

18. Soporte vectorial con el kernel radial: Se implementa con los datos con el conjunto de datos final con valor de escalado en verdadero.

```
modelo.svm.radial <- svm(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kernel = 'radial')
prediccion.svm.radial <- predict(modelo.svm.radial , datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

19. Soporte vectorial con el kernel linear: Se implementa con los datos con el conjunto de datos final con valor de escalado en verdadero.

```
modelo.svm.radial <- svm(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kernel = 'radial')
prediccion.svm.radial <- predict(modelo.svm.radial , datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

20. Soporte vectorial con el kernel polynomial: Se implementa con los datos con el conjunto de datos final con valor de escalado en verdadero.

```
modelo.svm.polynomial <- svm(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kernel = 'polynomial')
prediccion.svm.polynomial <- predict(modelo.svm.polynomial , datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```

21. Soporte vectorial con el kernel sigmoid: Se implementa con los datos con el conjunto de datos final con valor de escalado en verdadero.

```
modelo.svm.sigmoid <- svm(CantidadDias~., data = datos.aprendizaje, scale =TRUE, kernel = 'sigmoid')
prediccion.svm.sigmoid <- predict(modelo.svm.sigmoid , datos.prueba[, -which(colnames(datos.prueba) == 'CantidadDias')])
```


22. Reducción de dimensiones con algoritmo ACP: Se implementa con los datos con el conjunto de datos final con valor de escalado en verdadero, con validación cruzada y con dos componentes.

```
modelo.rd.ACP <- pcr(CantidadRMSEP(object, ...) ~., data = datos.aprendizaje, scale = FALSE, validation = 'CV')
modelo.rd.ACP
n.comp.rd <- which.min(RMSEP(modelo.rd.ACP)$val[1, 1, ]) - 1
n.comp.rd
prediccion.rd.ACP <- predict(modelo.rd.ACP, datos.prueba, ncomp = n.comp.rd)
```

23. Reducción de dimensiones con algoritmo MCP: Se implementa con los datos con el conjunto de datos final con valor de escalado en verdadero, con validación cruzada y con dos componentes.

```
modelo.rd.MCP <- pls(CantidadDias~., data = datos.aprendizaje, scale = FALSE, validation = 'CV')
modelo.rd.MCP
n.comp.rd <- which.min(RMSEP(modelo.rd.MCP)$val[1, 1, ]) - 1
n.comp.rd
prediccion.rd.MCP <- predict(modelo.rd.MCP, datos.prueba, ncomp = n.comp.rd)
```

A continuación, se muestra un gráfico de resumen con los modelos valorados y las métricas elegidas en el plan de pruebas:



3.4 Evaluación del modelo

A continuación, se muestra una tabla resumen con los resultados de las métricas elegidas para evaluar el modelo:

Modelos	Raíz de la desviación cuadrática media	Error absoluto medio	Error relativo	Correlación	Porcentajes de errores absolutos hacia arriba
Regresión Lineal	68,40	53,84	0,40	0,48	0,52
regresión penalizada - Ridge	68,50	53,88	0,40	0,48	0,53
regresión penalizada - Lasso	68,37	53,82	0,40	0,48	0,52
arboles de decision	39,03	26,49	0,20	0,87	0,22
Bosques aleatorios	16,50	5,63	0,04	0,98	0,04

Potenciación - gaussian	76,68	59,37	0,44	0,32	0,56
Potenciación - laplace	80,12	56,92	0,43	0,34	0,45
Potenciación - tdist	79,04	57,51	0,43	0,32	0,49
KNN - optimal	24,77	9,55	0,07	0,95	0,09
KNN - rectangular	26,46	9,87	0,07	0,94	0,13
KNN - triangular	24,09	9,23	0,07	0,95	0,09
KNN - epanechnikov	24,98	9,19	0,07	0,95	0,09
KNN - biweight	24,69	9,75	0,07	0,95	0,08
KNN - triweight	24,94	9,67	0,07	0,95	0,08
KNN - cos	24,98	9,11	0,07	0,95	0,09
KNN - inv	24,72	8,88	0,07	0,95	0,09
KNN - gaussian	26,15	9,52	0,07	0,94	0,10
svm - radial	80,73	57,42	0,43	0,11	0,47
svm - linear	27301030256,71	#####	204056646,26	-0,13	204356036,57
svm - polynomial	#####	#####	#####	-0,06	#####
svm - sigmoid	80,97	57,57	0,43	0,00	0,46
ACP	68,38	53,82	0,40	0,48	0,52
MPC	68,39	53,83	0,40	0,48	0,52

Después de evaluar los resultados se concluye que el modelo que se ajusta de mejor forma con el conjunto de datos final es el **“Bosques aleatorios”** porque presento los valores más bajos en las métricas “Raíz de la desviación cuadrática media” y “Error absoluto medio” en conjunto con los porcentajes mas bajo de “Error relativo” y “errores absolutos hacia arriba”; además cuenta con la “Correlación” más alta entre el valor real y la predicción.

4. Fase de evaluación

4.1 Evaluación de los resultados

Para la evaluación de los resultados se realizaron los siguientes pasos:

1. Se reentreno el modelo de “Bosques Aleatorios” pero con la totalidad del conjunto de datos desarrollado en la “Fase de preparación de datos”
2. Se realizaron las predicciones con el conjunto de datos a predecir, que serían los registros actuales de pedidos sin fecha de aplicación y su disponible diferente de 0, a este conjunto de datos se le transforman para dejar las mismas 26 variables antes definidas.

3. Una vez obtenida la predicción de la cantidad de días, se toma la fecha de creación del pedido y se le suma la cantidad de días de la predicción, la fecha resultante sería la fecha en la cual es más probable que se agote el disponible de ese pedido.

4.2 Proceso de revisión

En conjunto con un usuario experto y se ven los resultados de los pedidos con sus fechas de finalización probables y observa según el conocimiento del negocio del usuario experto que si son datos que se encuentran dentro de la realidad de los procesos actuales.

Por esta razón el modelo se da como aprobado por parte del usuario experto.

4.3 Determinación de futuras fases

El proceso de ejecución de los pedidos se ven regulados por las leyes del gobierno de Costa Rica, por ejemplo “Ley de Contratación Administrativa” y “Ley de la Moneda”.

Esta situación puede llegar a generar cambios bruscos en los comportamientos de los tiempos para las ejecuciones de los pedidos, por esta razón se recomienda como una fase futura realizar cada año las fases descritas en este informe, con el propósito de recalibrar oportunamente el modelo.

5. Fase de implementación

5.1 Plan de implementación

Para la implementación de este modelo se realizaron los siguientes pasos:

1. Instalación del modelo de “Bosques Aleatorios” en el “R services” del SQL SERVER de la Unidad de Inteligencia de la Información. Este procedimiento utiliza el modelo y guarda en una tabla el número del pedido y la cantidad de días de la predicción.
2. Agregar en el proceso de transformación de datos de la información del pedido del datawarehouse institucional, con el fin de agregar la fecha de aplicación probable.
3. Agregar en el reporte “Porcentajes de Ejecución Presupuestaria para los Centros Gestores y Rubros” la tabla con la información de los pedidos que son susceptibles a convertirse en compromisos no devengados según la fecha probable de finalización.

Montos Pendientes de Ejecutar para la Partida "2 - Materiales y Suministros" y la subpartida "20199 - Otros productos químicos y conexos"

Periodo	Número de documento	Fecha de finalización (Predicción)	Monto Susceptible de CHD	Ente emisor	Número de Contratación	Objeto Contractual
Total			97,480,395.17			
<input checked="" type="checkbox"/> Pedido			50,973,778.05			
2019	2019-093578	29/11/2019	189,155.00	SECCION DE COMPRAS MENORES	2019CD-000492-PROVCM	Compra de materiales para stock de la Sección de Mantenimiento y Construcción.
2019	2019-093579	29/11/2019	9,475.00	SECCION DE COMPRAS MENORES	2019CD-000492-PROVCM	Compra de materiales para stock de la Sección de Mantenimiento y Construcción.

5.2 Monitorización y Mantenimiento

Una vez implementado se considera en producción y en caso de identificar alguna anomalía se debe hacer el reporte del incidente para ser atendido por la Unidad de Inteligencia de la Información.

---Fin del documento ---

**GRUPO DE TRABAJO ESPECIALIZADO
TRANSFORMACIÓN DIGITAL**

**Coordinado por República Dominicana
Período 2023-2024**

Martín García Díaz

Nicaragua

Director General de la División General
de Tecnología de la Información y comunicaciones

Mario Enrique Oregel Torres

Guatemala

Gerente de Área de la Gerencia de Informática

Pablo Ernesto Santana Parada

El Salvador

Director de Desarrollo Tecnológico e información

Kattia Morales Navarro

Costa Rica

Directora de Tecnología de la Información y
Comunicaciones

Maritere Colón Domínguez

Puerto Rico

Jueza Superior
Directora Administrativa de los Tribunales Auxiliar

Edgar Rodríguez y Katya Quiel

Panamá

Director de Modernización y Desarrollo Institucional;
directora de Informática

Lourdes Carolina Munguía Díaz

Honduras

Jueza Coordinadora del Juzgado de Letras del Trabajo

República Dominicana

Arelis S. Ricourt Gómez,

Jueza Presidente Cámara Civil
Corte Apelación de La Vega

Edynson Francisco Alarcón Polanco

Juez Presidente Cámara Civil
Corte Apelación Distrito Nacional

Katerine A. Rubio Matos

Jueza de Paz

Welvis Beltrán

Director de Tecnología