



UNIVERSIDAD TÉCNICA  
FEDERICO SANTA MARÍA

Departamento de Obras Civiles

# **METODOLOGÍA DE MODELACIÓN DE DESEMPEÑO DE PAVIMENTOS URBANOS CON INTELIGENCIA ARTIFICIAL**

Memoria de Título presentada por

**Salvador Patricio Pérez Jara**

como requisito parcial para optar al título de la carrera de

**Ingeniería Civil  
Magister en Ciencias de la Ingeniería Civil**

Profesor Guía  
Aleli Osorio Lird

Octubre de 2023



UNIVERSIDAD TÉCNICA  
FEDERICO SANTA MARÍA

TÍTULO DE LA TESIS:

**METODOLOGÍA DE MODELACIÓN DE DESEMPEÑO DE  
PAVIMENTOS URBANOS CON INTELIGENCIA ARTIFICIAL**

AUTOR:

**SALVADOR PATRICIO PÉREZ JARA**

TRABAJO DE MEMORIA, presentado como requisito parcial para optar al título de la carrera de INGENIERÍA CIVIL de la Universidad Técnica Federico Santa María.

Nombre Prof. Guía

Alelú Osorio Lird.

Nombre Miembro 1 Comisión

Gabriel García Saa.

Nombre Miembro 2 Comisión

Héctor Allende Cid.

Valparaíso/Santiago, Chile, Octubre de 2023

# METODOLOGÍA DE MODELACIÓN DE DESEMPEÑO DE PAVIMENTOS URBANOS CON INTELIGENCIA ARTIFICIAL

Salvador Patricio Pérez Jara<sup>1</sup>, Alelí Osorio Lird<sup>2</sup>

1 Universidad Técnica Federico Santa María

2 Universidad Técnica Federico Santa María

## Resumen

Los modelos de desempeño de pavimentos son una herramienta sumamente útil para las agencias encargadas de la gestión vial, permitiendo estimar el comportamiento y designar la medida correctiva óptima para mantenimiento de las vías. Investigaciones recientes han presentado resultados favorables al utilizar técnicas de Machine y Deep Learning en la modelación del comportamiento de pavimentos.

En esta investigación se plantea una metodología de desarrollo de modelos de desempeño de primera fase para pavimentos urbanos, gestionados a nivel de red, para la predicción de la condición a corto y largo plazo utilizando técnicas de Machine y Deep Learning en su confección. Específicamente se utiliza la regresión de bosques aleatorios (RFR), regresión de vectores de soporte (VSR), regresor de refuerzo de gradiente (GBR), redes neuronales artificiales (ANN) y redes neuronales recurrentes (ANN). Con estos algoritmos se confeccionan modelos para predecir el Índice de Condición de Pavimentos Urbanos de Chile (ICPU) utilizando una base de datos sintética de elaboración propia en las simulaciones para luego evaluar su desempeño con datos reales obtenidos mediante procesos de auscultación manual.

En cuanto a los resultados obtenidos, al momento de examinar el rendimiento de los algoritmos con los datos provenientes de la base sintética, las iteraciones ofrecen resultados favorables para la predicción a corto plazo, obteniendo bajos errores promedio de predicción y resultados de RMSE próximos a cero. En tanto que, al momento de examinar el rendimiento con los datos reales de campo se obtienen errores menores al 10% y valores de RMSE bajos, lo cual resulta de interés para cada una de las alternativas de algoritmos mencionadas anteriormente, pues las sitúan como herramientas recomendables para realizar predicciones sobre el desempeño de los pavimentos urbanos.

Con respecto a la predicción de largo plazo, se generan curvas de desempeño para 2 escenarios acotados que representan calles de la red vial primaria de la comuna de Maipú y Macul. Cada una de las curvas posee un horizonte de predicción de 20 años desde el primer dato informado y dichas curvas se contrastan contra curvas generadas con datos de auscultación en terreno que fueron aunados bajo la metodología de ventanas. Los resultados de esta comparativa muestran que los modelos configurados con los algoritmos RFR y GBR poseen una predicción de alta precisión para un horizonte de predicción de hasta 10 años, puesto que, para horizontes más amplios, disminuye el desempeño.

Palabras claves: Machine Learning, Deep Learning, desempeño, modelos, pavimentos urbanos.

## 1 Introducción y Contextualización.

Las redes de pavimento juegan un rol fundamental dentro de la sociedad, pues más allá de cumplir su función primordial, permitir el traslado de personas y carga valiosa vía terrestre, son un elemento sumamente necesario para el desarrollo integrado de una nación (Solminihac et al., 2018). Por este motivo, resulta de gran relevancia el preservar sus características funcionales y estructurales en el tiempo, pues, de esta forma, se pueden sostener adecuadamente las comunicaciones, actividades económicas, sociales y todas aquellas que permiten el continuo desarrollo de un país.

Por tales motivos, las agencias de gestión de infraestructura vial deben velar por instaurar políticas de mantenimiento que permitan preservar las redes de pavimento en un nivel de servicio adecuado y, para ello, requieren de herramientas que permitan inferir cual es el mejor momento para intervenir una determinada vía buscando la optimización tanto del rendimiento material (durabilidad del pavimento) como del recurso económico destinado a estas actividades.

Para tomar estas determinaciones, las Agencias de gestión se valen de múltiples herramientas que ayudan a tomar la decisión de cuándo y cómo intervenir, entre ellas los modelos de desempeño, los cuales son expresiones que predicen la evolución del estado del pavimento en el tiempo, en base al conocimiento de sus condiciones al momento de puesta en servicio y en cualquier momento de su vida útil (Solminihac et al., 2018).

Respecto al desarrollo de modelos de desempeño, esta es una actividad que sufre ajustes conforme aparecen nuevos enfoques de modelación. Es así como en primera instancia se intentó explicar el comportamiento de los pavimentos mediante un enfoque empírico con modelos regresivos (lineales multivariados) y deterministas (Watanatada et al., 1987) que asocian características similares como estructura, tránsito o clima. Otros autores decidieron utilizar un enfoque probabilístico para la confección de modelos, apareciendo como opción viable los modelos con formulaciones bayesianas y también con “Cadenas de Markov” (Solario, et al., 2014; Osorio, 2015). Últimamente, la tendencia es la de incursionar con técnicas de Inteligencia Artificial (IA), esencialmente mediante la interacción de algoritmos de Machine y Deep Learning tales como “Vector Support Regression (VSR)”, “Random Forest Regression (RFR)”, “Artificial Neuronal Networks (ANN)” y “Recurrent Neuronal Networks (RNN)” (Mazari y Rodríguez, 2016; Marcelino et al., 2019; Hossain, et al., 2019; Wang, et al., 2020; Zhou, et al., 2021; Montecinos, 2022).

La utilización de estas técnicas ha demostrado la obtención de modelos con resultados de predicción dignos de atención, puesto que la versatilidad de los algoritmos, a diferencia de los modelos determinísticos y probabilísticos, permite la modelación no solo de múltiples escenarios, sino que permite también incorporar atributos explicativos que no necesariamente obedecen a comportamientos numéricos (variables categóricas como zonas climáticas o jerarquía de vías) o, prescindir, por ejemplo, de matrices de transición de probabilidad cuya obtención se dificulta si es que no se poseen datos representativos de la red vial o no se cuenta con un panel de expertos que ayude en su confección. Además, dado el alto potencial de procesamiento de datos se pueden generar predicciones con un notable nivel de precisión a corto y mediano plazo.

En esta investigación, se plantea una metodología para la utilización de diferentes algoritmos de Machine y Deep Learning en la construcción de modelos predictivos del desempeño de pavimentos, empleando para ello una base de datos sintética que simula el comportamiento en el tiempo de pavimentos urbanos de alta jerarquía de la Región Metropolitana de Santiago de Chile representado en la variación del Índice de Condición de Pavimentos Urbanos (ICPU) (Osorio, 2015). Las pruebas realizadas consisten en predecir el ICPU del año “t” utilizando información de diversos atributos de los años previos “t-1”, tales como Tránsito Medio Diario Anual (TMDA), ICPU y características estructurales como espesor de carpeta y Módulo Resiliente de la subrasante, en lo que equivale a la utilización de un enfoque dinámico de modelación según se plantea en investigaciones previas (Marcelino, et al., 2019; Yang, et al., 2021). Dichos análisis permitieron dilucidar que los algoritmos

RFR, VSR, ANN, RNN y GBR poseen buena capacidad predictiva y de aprendizaje para la resolución de este tipo de problemas.

Por último, cabe destacar que este trabajo se enmarca en el desarrollo del Proyecto FONDECYT 11201150 “Evaluación y Modelación del desempeño de Pavimentos Urbanos usando Machine Learning”, el cual persigue los objetivos de automatizar la evaluación de pavimentos mediante el empleo de algoritmos de Deep Learning enfocándolos a la detección y cuantificación de deterioros usando imágenes de bajo costo y, el correspondiente a lo desarrollado en este escrito, que busca evaluar si la confección de modelos de desempeño utilizando algoritmos de Inteligencia Artificial entrega resultados de mayor precisión que los modelos existentes para el análisis de pavimentos urbanos a nivel de red.

El éxito que pueda obtenerse en las dos aristas de investigación comentadas puede generar un gran impacto en la gestión de pavimentos urbanos, puesto que permitiría incorporar aspectos valiosos de la gestión de pavimentos a agencias que no necesariamente cuentan con los recursos para adquirir tecnología de punta que les permita monitorear y evaluar la condición de la red de forma continua, además de entregar una herramienta de predicción que ayude a tomar mejores decisiones de priorización y mantenimiento de la red de pavimentos urbanos.

### **1.1 Motivación.**

Las motivaciones para haber elegido este tema de investigación son variadas, pero, la más importante son las ganas de querer contribuir de forma concreta al desarrollo de la sociedad, de poder transformar años de formación y conocimiento en algo tangible y que permita, a cada uno de los miembros de este país, tener un mejor vivir.

De alguna forma, es una muestra de agradecimiento a los más de 18 años de constante formación académica en donde me topé con increíbles maestras y maestros, quienes supieron estimular en forma notable mis ganas de aprender, de desarrollar conocimiento y de querer conseguir mediante ello una sociedad mejor. Es un agradecimiento a mis amigas y amigos, por allanar este tortuoso camino con sus risas y alientos y no dejarme caer cuando me inundaron malos pensamientos. Es una muestra de agradecimiento a mi familia, quienes fueron siempre mi sostén principal, quienes me provisionaron con todas las herramientas necesarias para estar en este punto cúlmine de la vida universitaria, a mi hermana por ser tolerante con su hermano mal genio, a mi mamá que con todo su amor me enseñó a leer, escribir y estudiar, a mi papá por siempre creer en que podía ser grande, que siempre me instó a realizar las cosas que me hicieran feliz y por darme la lección de que vine a este mundo a dejarlo mejor de como lo encontré.

Chile es un país en vías de desarrollo y, ante tal escenario, las y los ingenieros tenemos el deber de aportar con conocimiento, talento y creatividad a encontrar soluciones a los diversos problemas que aquejan a la sociedad. En mi caso puntual, mi misión es colaborar en la optimización de los sistemas de gestión de pavimentos urbanos, para que puedan nutrirse de herramientas que otorguen información certera y relevante, que les permitan tomar mejores decisiones en cuanto a cuándo y cómo preservar los pavimentos de la red, colaborar para que la respuesta comience a ser más preventiva que reactiva, para que el nivel de servicio a los usuarios de la red sea mejor que el mínimo deseable, para que la infraestructura vial urbana tome mayor valor, para que tengamos un mejor entorno visual y para que todos vivamos mejor.

### **1.2 Proyecto FONDECYT 11201150.**

El principal propósito de la gestión de pavimentos es el desarrollo de programas de conservación, mantenimiento y rehabilitación, P & M & R. Si bien se dispone de equipos, herramientas y metodologías bien calibradas para la evaluación de pavimentos, estas tienden a ser aplicadas a las jerarquías más altas de la red vial urbana debido a su alto costo de adquisición y operación, el que solo puede ser solventado por agencias viales de grandes recursos. En el caso puntual de Chile, la mayor parte de la red vial urbana está bajo tuición de agencias gubernamentales locales (Municipios), organizaciones que, si bien poseen recursos económicos, deben saber distribuirlo en una variedad de activos de infraestructura además de

los pavimentos urbanos, razón por la cual no se puede invertir en recursos técnicos novedosos y no se logra implementar la esencia de la gestión de pavimentos.

Dicho lo anterior, existe la necesidad de aprovechar el desarrollo tanto de nuevas tecnologías como de herramientas de procesamiento de datos para así optimizar, al menor costo posible, los sistemas de gestión de pavimentos en el país. Es así como la inteligencia artificial (IA) ha estado a la vanguardia en la actualización tanto de los procesos de evaluación de pavimentos como de la modelación de su comportamiento en el tiempo, puesto que mediante la utilización de sus herramientas de procesamiento de datos se pueden analizar los distintos tipos de deterioros que afectan la superficie mediante imágenes o modelar la condición de la superficie por medio de la conjunción de otras variables medibles, como parámetros estructurales, flujo vehicular o condición actual.

De esta forma, queda pendiente la tarea de desarrollar metodologías para aplicar las técnicas de análisis y herramientas de inteligencia artificial a la gestión de pavimentos urbanos, con miras a actualizar procedimientos, agilizar las tareas, incrementar el desempeño de las redes de pavimentos y, lo más importante, mejorar el nivel de servicio a los usuarios.

El Proyecto FONDECYT 11201150 propone automatizar la evaluación de pavimentos utilizando imágenes de bajo costo, obtenidas por un sistema de adquisición de imágenes con cámaras que cumplan con la misma filosofía económica. Las cuales son procesadas mediante algoritmos de Inteligencia Artificial, como Redes Neuronales Convolucionales (CNN), con el fin de clasificar y cuantificar el deterioro estructural superficial. Esto con miras a obtener el Índice de Condición de Pavimentos Urbanos (Osorio, 2013), el cual, además de guiar las decisiones para la implementación de labores de P & M & R, permita también, con la consecuente obtención suficiente de datos, modelar el comportamiento de las estructuras de pavimento en el tiempo. Esto último también con técnicas de Inteligencia Artificial, como lo es el empleo de algoritmos regresivos como árboles de decisión (DT), vectores de soporte (SVR), bosques aleatorios (RFR), regresores de refuerzo de gradiente (GBR) o modelos regresivos de inspiración biológica como las redes neuronales artificiales (ANN) o las redes neuronales recurrentes (RNN).

### **1.2.1 Objetivos del Proyecto.**

Contextualizado lo anterior, se presentan a continuación los objetivos del Proyecto FONDECYT 11201150.

- General:

El objetivo principal de esta investigación es **“mejorar la eficiencia de la evaluación y la precisión de los modelos de desempeño para la condición del pavimento urbano, utilizando equipos de bajo costo para la recopilación de datos de campo y herramientas de aprendizaje automático para el procesamiento y análisis de datos”**.

- Específicos:

El proyecto cuenta con tres objetivos específicos:

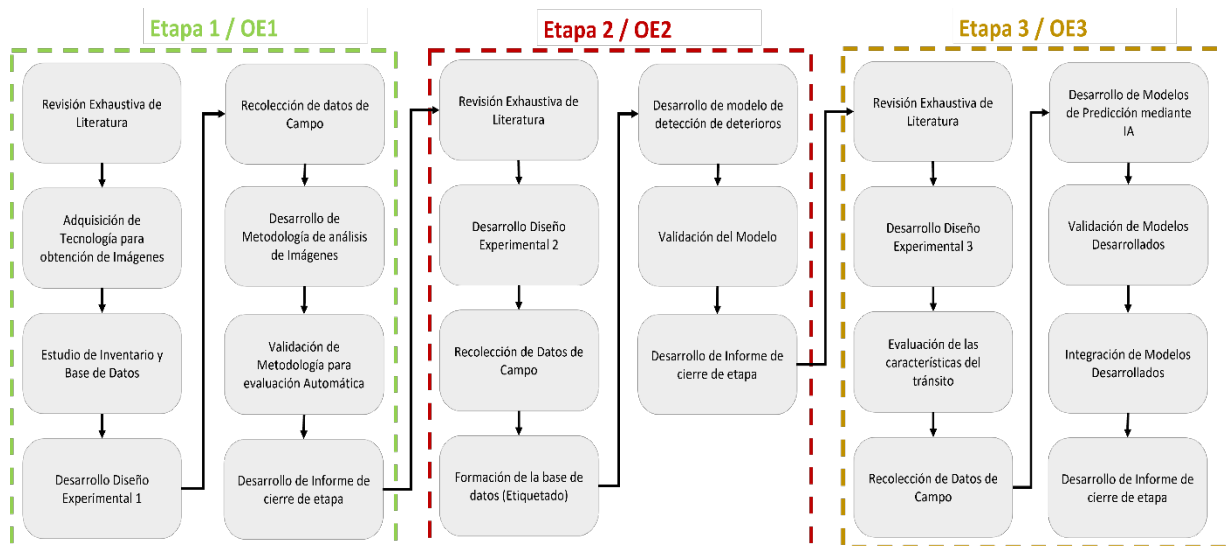
1. Aplicar y validar una metodología para la recopilación de datos de campo de deterioros de pavimentos urbanos utilizando imágenes de bajo costo.
2. Aplicar y validar algoritmos de Deep Learning para la detección automática de deterioros en el pavimento urbano a partir de imágenes recolectadas en terreno.
3. Desarrollar y validar modelos de condición de pavimentos urbanos utilizando algoritmos de inteligencia artificial, considerando una combinación de herramientas para la predicción a corto y largo plazo.

### **1.2.2 Etapas del Proyecto FONDECYT 11201150.**

Para conseguir los diversos objetivos del proyecto, este se subdivide en tres grandes etapas, las cuales se exponen a continuación:

1. Desarrollo y validación de una metodología para la recolección de datos de campo de deterioros de pavimentos urbanos con imágenes de bajo costo.
2. Análisis del estado del pavimento urbano mediante la utilización de técnicas de Deep Learning
3. Modelado del desempeño del pavimento urbano mediante la utilización de técnicas de Inteligencia Artificial.

Cada una de las etapas guardan relación en un orden secuencial tipo cascada, el cual se vislumbra de mejor manera en la figura 1.



**Figura 1. Muestra diagrama metodológico con las fases del Proyecto FONDECYT 11201150 y sus respectivas actividades.**

Dicho todo lo anterior, esta tesis de investigación cumple la misión de dar soluciones a la tercera etapa del proyecto FONDECYT 11201150 **“Modelado del desempeño del pavimento urbano mediante la utilización de técnicas de Inteligencia Artificial”** y su objetivo específico asociado **“Desarrollar y validar modelos de condición de pavimentos urbanos utilizando algoritmos de inteligencia artificial, considerando una combinación de herramientas para la predicción a corto y largo plazo”**.

### 1.3 Definición del problema.

La tesis de investigación busca desarrollar modelos de desempeño o condición de pavimentos urbanos utilizando Inteligencia Artificial. Sin embargo, para poder desarrollar una herramienta de este estilo, primero que todo, se deben estudiar y comprender las variables que explican el deterioro de un pavimento y su progresión en el tiempo.

Así, deberán tenerse en cuentas aspectos como el suelo de fundación del pavimento, el diseño estructural (distintas capas y sus espesores), la materialidad de la capa de rodadura, la función que preste la vía, el tipo de tránsito que recibe, la jerarquía, etc. Deben estudiarse además posibles incidencias de solicitaciones climáticas como las precipitaciones, temperatura, ciclos de hielo y deshielo, entre otras.

Expuesto lo anterior, el primer análisis debe centrarse en establecer los principales atributos que expliquen la progresión del deterioro con miras a generar modelos representativos a la realidad de los pavimentos urbanos de Chile. En resumidas cuentas, el problema queda enmarcado en lo siguiente:

- **“Entender el comportamiento de los pavimentos urbanos para, mediante la utilización de herramientas de Inteligencia Artificial, poder predecir, en forma eficiente, su deterioro en el tiempo”**

Ahora bien, lo recién comentado supone el problema técnico, sin embargo, existen otras inclemencias que pueden dificultar el correcto desarrollo de la arista de investigación y que tienen que ver con cómo se realiza la gestión de los pavimentos urbanos.

Según lo establece la legislación, los municipios son los encargados de administrar los bienes nacionales de uso público en sus territorios, entre los que se encuentran las plazas, puentes, calles y caminos públicos. Para lo anterior requieren contar con información certera del estado de las calles que les permita elaborar y proyectar planes de mantenimiento en el momento adecuado, que posteriormente se ejecutan mediante recursos entregados por la gobernación regional (Venegas, 2022; Diario Oficial de la República de Chile, 1992; Diario Oficial de la República de Chile, 2005; Diario Oficial de la República de Chile, 2006).

La situación antes descrita repercute en múltiples problemas, el primero de ellos radica en que los municipios poseen múltiples funciones y la gestión de los pavimentos no es siempre la primordial. Por otra parte, existe una amplia variabilidad en la composición de ingresos entre los diferentes municipios (CEP. 2020), lo que incide en que no siempre se puede asignar la misma cantidad de recursos a la gestión de los pavimentos, por lo que la condición de la red urbana es sumamente heterogénea en el país al aplicar medidas correctivas diferentes, pues cada municipio lleva adelante la gestión de los pavimentos en la medida de sus posibilidades.

¿Cómo repercute esto? En qué, primero, existen múltiples escenarios de pavimentos urbanos solo desde el análisis de la materialidad, puesto que existen pavimentos rígidos, flexibles, mixtos (recapados asfálticos sobre hormigón o hormigones sobre asfaltos) y adoquines. Por lo demás, las actividades de preservación que se asignen difieren entre municipios, por lo que la real condición de los pavimentos es heterogénea a lo largo y ancho del país.

Por último, no existe tampoco una cultura de registro de datos de la puesta en servicio de caminos, sobre cuando se realizan intervenciones sobre los pavimentos, de los espesores reales de las capas de rodadura y mucho menos del monitoreo de la condición de los pavimentos. Todo esto dificulta posibles asociaciones de patrones y la adecuada comprensión y mancomunación de las variables que están incidiendo en la progresión del deterioro, aspectos fundamentales para una correcta modelación. Por ende, podemos establecer un segundo problema el cual se enuncia de la manera siguiente

- ***“Configurar un escenario o familia específica de pavimentos urbanos que contenga condiciones de borde conocidas y manejables para la adecuada modelación de su desempeño en el tiempo”***

Como se aprecia, la tesis pretende dar solución a estas dos problemáticas enunciadas.

#### **1.4 Hipótesis de Investigación.**

Modelos de desempeño de pavimentos ya se han desarrollado con anterioridad. Sin embargo, estamos en un exponencial crecimiento de las tecnologías informáticas y de análisis de datos de la mano de la Inteligencia Artificial, por lo que muchas de las herramientas de análisis ingenieril pueden reinventarse utilizando estas herramientas y alcanzar, incluso, un nivel de precisión o comprensión de su campo de dominio mucho mayor.

Solminiach plantea que los sistemas de gestión requieren desarrollo continuo y adaptarse también al cambio tecnológico (Solminiach, et al.,2018), estamos en la etapa perfecta para indagar nuevas formas y contribuir a optimizar las metodologías regentes, corresponde hacerlo.

De esta forma, la hipótesis de investigación se enuncia de la manera siguiente:

- ***“El rendimiento de la condición del pavimento urbano modelado con una combinación de algoritmos de Inteligencia Artificial para predicciones a corto y largo plazo presenta resultados más precisos que los modelos existentes para análisis a nivel de red.”***

#### **1.5 Objetivos.**

Para el desarrollo de la arista de investigación se plantean los siguientes objetivos

##### **1.5.1 General.**

*Proponer y calibrar una metodología de modelación del comportamiento de pavimentos urbanos utilizando Machine Learning y Deep Learning, con aplicación a un conjunto de datos sintéticos, y validar con una base de datos reales de una red urbana acotada de la Región Metropolitana de Santiago de Chile.*

### **1.5.2 Específicos.**

- *OE1: Proponer y desarrollar metodología de modelación de la condición de pavimentos urbanos utilizando diferentes algoritmos de IA, específicamente Regresor de Bosques Aleatorios (RFR), Regresión de Vectores de Soporte (VSR), Regresor de Refuerzo de Gradiente (GBR), Redes Neuronales Artificiales (ANN) y Redes Neuronales Recurrentes (RNN). Indicando recomendaciones sobre el uso de variables y el tratamiento apropiado de la base de datos para su correcta aplicación.*
- *OE2: Aplicar la metodología de modelación utilizando una base de datos sintética que permita la simulación y entrenamiento de las distintas alternativas de algoritmos utilizados.*
- *OE3: Validar la metodología con la aplicación de los modelos a una base de datos real de una red urbana acotada de la Región Metropolitana de Santiago de Chile.*

## **2 Marco Conceptual de la Investigación.**

### **2.1 Sistemas de gestión de pavimentos urbanos (SGPU).**

Es un tipo de sistema que se encarga esencialmente de la preservación de los pavimentos de la red vial urbana, es decir, su propósito es diagnosticar, evaluar, planificar y programar el mantenimiento de los pavimentos en zonas urbanas a lo largo de su ciclo de vida optimizando el uso de recursos (Solminihac, et al., 2018).

Cabe destacar, que este tipo de gestión difiere del contexto interurbano en múltiples aspectos, puesto que los pavimentos urbanos poseen una serie de interacciones con otros sistemas o elementos de infraestructura urbana con los cuales debe aprender a coexistir. Así, se debe enfrentar la comunión con redes de agua potable, alcantarillado, sistemas colectores de aguas lluvia, redes de telefonía, electricidad, etc. (Solminihac, et al., 2018). Lo cual, obviamente, dificulta las tareas de gestión por requerir de una exhaustiva planificación.

Un aspecto determinante para realizar la gestión de los pavimentos urbanos es conocer el tipo de tránsito que hace uso de la vía. Saber si los flujos son altos o bajos, si existe presencia o no de tránsito pesado, de transporte público, tener nociones de la velocidad de circulación sobre las vías ayuda y complementa la comprensión del deterioro que estas puedan tener. De esta forma, tener un correcto catastro de los flujos y tipos de tránsito resulta fundamental para realizar una adecuada gestión (Solminihac, et al., 2018).

#### **2.1.1 Tipos de gestión.**

##### **2.1.1.1 Gestión a nivel de proyecto.**

Considera la infraestructura vial presente en un arco o segmento específico de una red vial, como, por ejemplo, un tramo concesionado de una ruta. Su nivel de detalle es alto y generalmente cuenta con datos de entrada provenientes de un seguimiento continuo de las características de dicho tramo (Solminihac, et al., 2018)

##### **2.1.1.2 Gestión a nivel de red.**

La gestión a nivel de red considera una red vial que abarca un determinado territorio y, por tanto, permite tomar decisiones que afectan a toda la infraestructura vial presente en dicho territorio. Involucra la priorización de los proyectos que podrían llevarse a cabo sujeto a la disponibilidad presupuestaria en un período determinado (Solminihac, et al., 2018).

Como principal diferencia entre ambas modalidades de gestión, es que la gestión a nivel de proyecto, en base a la disponibilidad presupuestaria, busca preservar el proyecto para que preste las mejores condiciones de servicio a los usuarios, en tanto que, en la gestión a nivel de red, se busca priorizar para preservar la red vial en un nivel de servicio mínimo deseable a los usuarios.

### 2.1.2 Componentes de un sistema de gestión de pavimentos urbanos.

Habiendo estudiado las funciones y propósitos de los sistemas de gestión de pavimentos urbanos, deben explicitarse ahora sus componentes con tal de tener nociones de su funcionamiento interno.

Dicho lo anterior, Solminihac, et al., 2018 caracterizan los SGPU como un cuerpo de tres componentes. La agencia vial, un sistema decisional y un sistema de información. Por otra parte, un SGPU debe también incluir un sistema analítico que optimice la asignación de los recursos disponibles y priorice los proyectos de mantenimiento. Estos sistemas incluyen una base de datos, información de la condición funcional y estructural de los pavimentos, **modelos de comportamiento de la condición** de los pavimentos, estándares de mantenimiento, costos de mantenimiento y un método de evaluación y optimización económica (Haas, et al., 1994).

Lo anterior mencionado, da cuenta de la importancia que tienen dichas herramientas dentro de un SGPU, puesto que si se posee un buen sistema de captura de datos que nutra adecuadamente a los sistemas de información, los sistemas decisionales pueden tomar determinaciones adecuadas y certeras en cuanto a priorización de tramos a intervenir y, por ende, la agencia vial estará asignando recursos apropiadamente optimizando así la gestión económica de la red vial en lo que sería una tríada virtuosa de funcionamiento.

## 2.2 Modelos de desempeño de pavimentos.

Los modelos de comportamiento (o desempeño) son expresiones matemáticas que predicen la evolución del estado del pavimento en el tiempo, en base al conocimiento de sus condiciones al momento de puesta en servicio y en cualquier momento de su vida útil. Permiten predecir los efectos a corto y largo plazo de las mantenciones, con el fin de estimar razonablemente las oportunidades en que sea necesaria alguna operación de mantenimiento, el nivel de deterioro resultante y su progresión en el tiempo (Solminihac, et al., 2018).

Como se puede ver, los modelos de rendimiento son una poderosa herramienta para los sistemas de gestión de infraestructura vial, puesto que más allá de analizar y predecir el comportamiento estructural, son un factor de decisión importante a la hora de seleccionar medidas correctivas, lo que permite a las agencias viales tener un enfoque predictivo y optimizar recursos económicos al incorporar nociones que permiten determinar instantes de tiempo recomendables para realizar las respectivas intervenciones a las vías.

En cuanto a los tipos de modelos de desempeño, existen variadas formas de clasificación, una de ellas, es de acuerdo con el enfoque que estos tengan.

### 2.2.1 Naturaleza de los modelos de desempeño.

- Según su enfoque:

En primer lugar, encontramos los **modelos empíricos**, que predicen la variable dependiente por medio de parámetros independientes como la edad del pavimento y deterioros superficiales que se encuentran en bases de datos conformadas con anterioridad (Osorio, 2015). Por otra parte, están los **modelos mecanicistas**, que estudian el comportamiento basándose en propiedades físicas y mecánicas tanto del pavimento como de las estructuras de soporte (base o subbase) (Solminihac, et al., 2018). También, existen modelos que combinan ambas perspectivas como lo son los **modelos empírico-mecanicistas** en donde el deterioro estructural o funcional está relacionado con algún parámetro de respuesta (Osorio, 2015). Otro tipo de modelo son los subjetivos o probabilísticos, los cuales se nutren de herramientas probabilísticas para estudiar el comportamiento.

- Según presencia o no de intervenciones en el pavimento

En este sentido, existen modelos **de primera y segunda fase**. Los de primera fase se caracterizan por predecir la forma en que una determinada característica progresará sin que ocurran intervenciones en el

pavimento. Caso contrario, los modelos de segunda fase asumen la presencia de intervenciones y se preocupan de analizar qué efectos tiene esta sobre la serviciabilidad de la vía.

- Según la historia de datos

En el caso de que se posea una gran cantidad de datos previos de terreno que describan la historia del pavimento, pueden generarse modelos continuos (con formas continuas), que permitan predecir características funcionales, este tipo se conoce como **modelo absoluto**. Si no se posee una fuente de datos confiable que describa la historia del pavimento, aparecen los **modelos incrementales**, los cuales permiten estimar las características funcionales basándose en la condición actual del pavimento, pero incorporando también variables estructurales y climatológicas al análisis.

### 2.2.2 Modelos de desempeño regresivos.

Estos modelos estiman la condición mediante un valor preciso, calculado con funciones matemáticas que relacionan de una u otra forma un indicador de deterioro con un conjunto de variables explicativas.

El modelo de análisis de regresión realiza un análisis de tendencia del comportamiento en el tiempo, a través de datos históricos que han sido recolectados durante la vida útil de la infraestructura. Los datos necesarios para el uso del modelo de regresión deben ser agrupados con características similares como estructura, tránsito, clima, etc. (Valle, 2019). De esta forma, se encuentran **modelos de regresión lineal y múltiple**, todo dependiendo de la cantidad de variables explicativas que le den sentido a la variable dependiente. Cabe mencionar también, que este tipo de modelo, al ser elaborado mediante el uso de funciones matemáticas, es de carácter continuo y su nivel de precisión dependerá de cómo se ajuste dicha

Este tipo de modelo tiende a encontrarse en modelos de deterioros específicos como agrietamientos, fatiga y ahuellamiento en pavimentos asfálticos y, también, para el estudio de índices de serviciabilidad, rugosidad y condición estructural.

### 2.2.3 Modelos de desempeño probabilísticos.

A diferencia de los análisis regresivos, las metodologías a través de **las cadenas de Markov** son utilizadas para determinar a través de análisis probabilísticos el estado futuro de la infraestructura de un pavimento basándose de su estado actual (Valle, 2019). Lo anterior mencionado resulta ventajoso ante un contexto de análisis como el presentado para los pavimentos urbanos en Chile, en donde no se posee una base de datos de largo plazo en donde se haya estudiado continuamente el progreso del deterioro de calles y avenidas. Por este motivo es que las metodologías Markovianas se posicionan como una buena opción para la confección de modelos de desempeño y así lo demuestra la investigación realizada por Osorio, 2015.

Con respecto a los tipos de metodología, existen dos tipos. Las **Cadenas de Markov** y los **Métodos de Montecarlo con Cadenas de Markov (MCMC)**. El primero, se ha aplicado de manera amplia para desarrollar modelos probabilísticos de deterioro, en tanto que los métodos MCMC se han utilizado para aproximar formulaciones bayesianas relacionadas con la estimación de parámetros de modelos deterministas (Solario, et al., 2014).

- Cadenas de Markov

Adentrémonos en las Cadenas de Markov. Esta metodología se refiere a un proceso estocástico, es decir, no determinista, con las siguientes características:

1. Es discreto en el tiempo.
2. Se define un espacio finito de espacios posibles.
3. El cambio de estado está determinado por un conjunto de probabilidades.
4. La probabilidad de que el proceso pase del estado  $i$  al  $j$  depende únicamente del estado actual y no de los estados anteriores.

Esta última es la propiedad que otorga ventaja a las Cadenas de Markov por sobre los otros métodos, pues configura una herramienta que puede ser utilizable incluso cuando no se poseen datos históricos de aquella condición que se quiera modelar.


Para utilizar las cadenas de Markov, se parte de los siguientes supuestos (Solorio, et al., 2014):

- Los estados del proceso corresponden a los distintos niveles de deterioro del pavimento, definidos en términos de indicadores de daño como la irregularidad o el agrietamiento.
- El nivel de deterioro se expresa a través de estados o bandas de condición definidos en términos de algún indicador de interés (PCI, PSI, IRI, ICPU).
- Los estados del proceso ocurren en ciclos de servicio con una duración fija, normalmente de un año.
- Se asume que el deterioro de carreteras cumple con la propiedad de Markov, es decir, que el estado futuro depende únicamente del estado actual.

Entonces, cuando se utilizan cadenas de Markov, el estado del pavimento en un ciclo de servicio específico viene denotado por un vector de estados, el cual representa la condición de un tramo de vía como una colección de las fracciones que se encuentran en cada uno de los estados o bandas de condición que se definan.

$$a_t = (a_1, a_2, \dots, a_n)$$

En la investigación planteada por Solorio, et al. 2014, se realiza un modelo de desempeño para la predicción de IRI en carreteras de México, investigación en la cual se generan bandas de condición para la confección de los vectores de estado, tal cual como se ilustra en la siguiente imagen.



**Figura 2. Muestra vectores de estado seccionados según bandas de condición de IRI. (Fuente: Solorio, et al. 2014).**

Ahora, las interrogantes recaen en cómo obtener los vectores de estado asociados a cada ciclo de servicio, y la respuesta recae en la aplicación de una Matriz de Probabilidades de Transición. Esta matriz, agrupa todas las probabilidades  $p_{ij}$  de que la condición del pavimento pase del estado  $i$  al estado  $j$  entre dos ciclos de servicio consecutivos.

$$P = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \vdots & & & \vdots \\ p_{n1} & p_{n2} & \dots & p_{nn} \end{bmatrix}$$

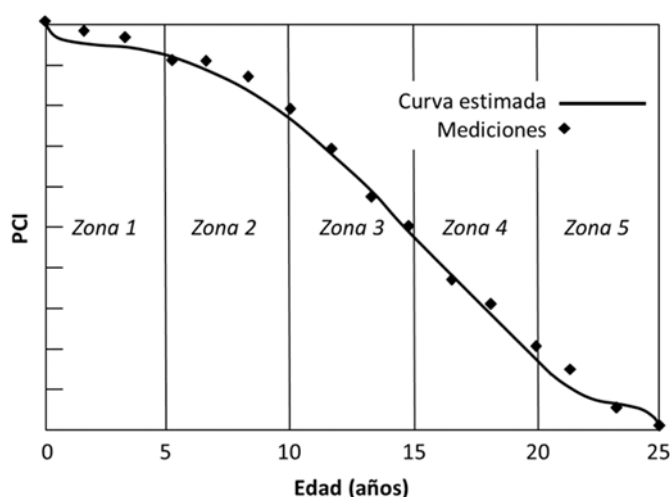
**Figura 3. Muestra una matriz de probabilidades de transición. (Fuente: Solorio, et al. 2014).**

Como bien se mencionó, esta matriz está compuesta por una serie de probabilidades lo que lleva al cuestionamiento lógico de ¿Cómo se obtienen dichas probabilidades? Y la respuesta es simple, se calculan mediante el cociente entre un número de tramos que pasan del estado “i” al “j” en un ciclo de servicio sobre el total de tramos que se encuentran en la condición “i” o, sencillamente, adoptan el valor que le entreguen un panel de expertos.

Ahora, sobre las Matrices de transición de probabilidad, Cuando se asume que las MTP no cambian en el tiempo, se habla de “Cadenas Homogéneas”. En ese caso, el vector de estado asociado a un ciclo de servicio i se calcula sencillamente como el vector de estado del ciclo anterior por la MTP.

$$a_t = a_{t-1} * [MTP]$$

Sin embargo, las variables explicativas del deterioro del pavimento cambian en el tiempo, lo que implica que la MTP no puede ser constante en todo el período de análisis. Esto implica que debiesen utilizarse MTP “no homogéneas” (que varíen entre cada ciclo de servicio) para poder predecir el deterioro en el tiempo. Sin embargo, el problema puede ser simplificado generando zonas homogéneas según lo explicado por Butt, et al. 1994, en donde se pueden definir MTP homogéneas para ventanas de tiempo de 5 años, tal cual como se visualiza en la imagen.



**Figura 4. Muestra un análisis de variación de PSI subdividido en zonas homogéneas. (Fuente: Solorio, et al. 2014).**

Si bien, realizar esta “adecuación” del problema ayuda a mejorar la precisión de los modelos, Solorio es enfático en mencionar que las cadenas homogéneas pueden perder su capacidad predictiva conforme avanza el período de análisis, esto debido principalmente a que se ignora la evolución de las variables explicativas de gran importancia como lo puede ser el volumen de tránsito o la capacidad estructural del pavimento. Por estas razones, se sugiere de forma implícita que modelos como estos sean utilizados para períodos de análisis de corto plazo y, en caso de necesitar una predicción con mayor nivel de precisión, utilizar los métodos MCMC.

- Métodos de Montecarlo con Cadenas de Markov

En el mismo trabajo de Solorio, et al. 2014, se señala que estos métodos comprenden un conjunto de algoritmos para la aproximación numérica de una distribución de probabilidad mediante la construcción de una cadena de Markov cuya distribución de equilibrio coincide con la distribución buscada, entre los algoritmos más conocidos destacan el Muestreo de Gibbs y el Metropolis-Hastings.

Como se mencionó anteriormente, el método se utiliza para aproximar formulaciones bayesianas las cuales consideran los parámetros de una distribución de probabilidad como variables aleatorias y estiman esos mismos parámetros a partir de una distribución a posteriori, la cual se obtiene combinando

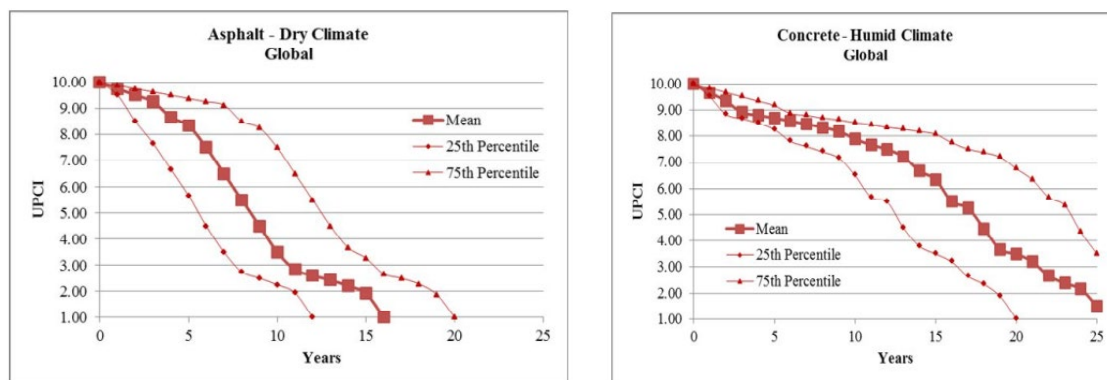
las creencias del analista con respecto a la forma en que se distribuyen los parámetros con datos muestrales de la población de interés.

A fin de cuentas, para poder utilizar esta metodología se debiese seguir la siguiente receta (Solorio, et al., 2014):

1. Considerar a los parámetros del modelo como variables aleatorias (enfoque bayesiano).
2. Elegir una distribución de probabilidad a priori para cada parámetro.
3. Definir la función de verosimilitud en términos de la evidencia experimental disponible y la distribución a priori.
4. Aplicar el teorema de Bayes para obtener la distribución a posteriori de los parámetros.
5. Aproximar la solución mediante métodos MCMC.

Un caso exitoso de la aplicación de los MCMC son los modelos desarrollados por Osorio, 2015 para el sistema SGPUC, en donde se obtuvieron curvas de desempeño para un período de análisis de 25 años confeccionando modelos para la red primaria, secundaria y local para pavimentos asfálticos y de hormigón en clima mediterráneo (6 en total), otro para pavimento asfáltico en clima seco y un último para pavimento de hormigón en clima húmedo.

A continuación, se exponen los últimos dos modelos mencionados.



**Figura 5. Muestra modelos de desempeño elaborados con herramientas de MCMC (Fuente: Osorio, 2015)**

Hasta aquí se han estudiado dos formas de confeccionar modelos de desempeño, el uso de métodos de regresión, metodología determinista, y la utilización de métodos Markovianos, metodología probabilística. Ambas técnicas han sabido otorgar buenos resultados tanto en el contexto urbano como en el interurbano. Sin embargo, con el progreso de las tecnologías de la información, hoy existen otras alternativas que podrían dar buenos resultados y ser incluso más precisas. En este caso, se habla de la utilización de herramientas de inteligencia artificial.

#### **2.2.4 Modelos de desempeño con inteligencia artificial.**

El avance de las tecnologías de la información permite incorporar nuevas herramientas para resolver los mismos problemas que regularmente se tienen, pero ahora con herramientas computacionales, lo cual permite optimizar, sobre todo en tiempo, las actividades que comúnmente desarrollaba el ser humano en terreno. En este sentido, la exploración del estado del arte en el área de la gestión de infraestructura no se queda atrás, pues los investigadores han realizado esfuerzos por actualizar las metodologías incorporando inteligencia artificial, pero ¿Qué se entiende por inteligencia artificial?

- Inteligencia Artificial

Según Marvin Minsky, la inteligencia artificial es “una disciplina que se encarga de crear máquinas programadas que sean capaces de hacer cosas que requieren la misma inteligencia que si fuesen hechas por humanos”. En palabras más técnicas, el académico de la Universidad de Chile, Rodrigo González,

la explica como procedimientos automáticos mediante los cuales se hacen cosas inteligentes propias de los humanos aplicando un algoritmo (Ramírez, 2021)

Dentro de las diferentes alternativas de algoritmos de inteligencia artificial es que aparecen herramientas como el Machine y el Deep Learning.

- Machine Learning (ML)

O aprendizaje automático, es el uso de algoritmos para organizar datos, reconocer patrones y hacer que computadores puedan aprender con esos modelos y generar insights inteligentes sin necesidad de pre-programación. (Salesforce, 2018). Algunos ejemplos de algoritmos de ML son los árboles de decisión (DT), Bosques Aleatorios (RFR), Vectores de Soporte (SVR) y regresor de refuerzo de gradiente (GBR).

- Deep Learning (DL)

O aprendizaje profundo, es la parte del aprendizaje automático que, por medio de algoritmos de alto nivel, imita la red neuronal del cerebro humano. (Salesforce, 2018)

Distintos investigadores del orbe han estado utilizando estas herramientas para desarrollar tanto metodologías de evaluación de pavimentos como de desarrollo de modelos de desempeño, siempre basándose en la utilización de una de las dos herramientas recién descritas, principalmente de Deep Learning, por su mayor poder de análisis. En general, los distintos autores basan sus estudios en la utilización de distintos algoritmos como lo son las Redes Neuronales Artificiales (ANN) o las Redes Neuronales Recurrentes (RNN).

Ahora bien, dentro del mundo de la Inteligencia Artificial se tienen distintos tipos de problema y, por ende, los algoritmos presentan distintos enfoques según la problemática que intentan resolver. Puntualizando, los problemas en IA se agrupan en dos grandes tópicos, “Clasificación” y “Regresión”.

- Problemas de Clasificación:

En este tipo de problemas, el output del algoritmo es una categoría de un conjunto infinito y sin estructura más rica que la de un conjunto finito. Por ejemplo, distinguir entre humanos, perros y gatos. (Ñanculef, 2022).

- Problemas de Regresión:

En este tipo de problemas, el output del algoritmo es un número o conjunto de números reales (Ñanculef, 2022). Por ejemplo, el precio de algún producto, la edad de algún elemento, valores de la bolsa de comercio, temperatura, caudales o, ligado al caso puntual de esta tesis, la métrica de algún índice que refleje la condición de un pavimento.

Algoritmos orientados a resolver problemas de regresión hay múltiples. Sin embargo, los que más se observan en el contexto de gestión de pavimentos son los Bosques Aleatorios (Random Forest) y las Redes Neuronales en su variedad de artificiales y recurrentes.

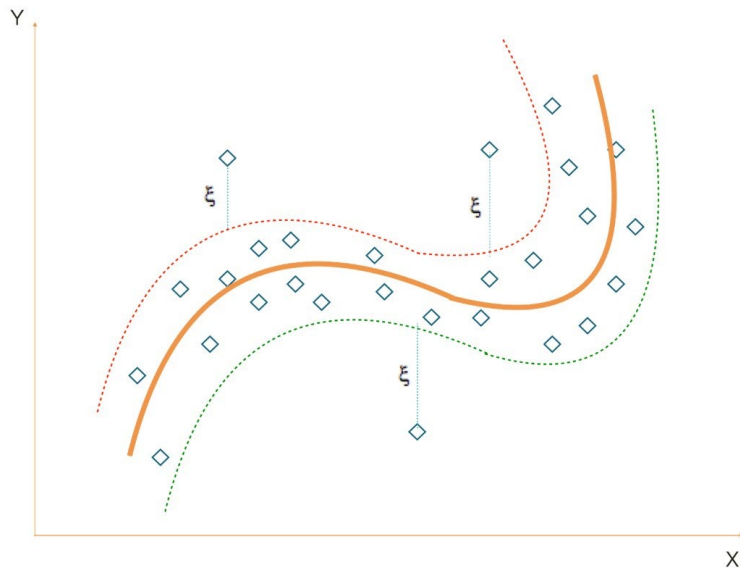
A continuación, se entrega una breve descripción de los algoritmos anteriormente mencionados junto con otros de interés.

#### **2.2.4.1 Breve descripción de algoritmos.**

- Vectores de Soporte (SVR)

Es un tipo de algoritmo del ML que se basa en buscar la curva o hiperplano que modele la tendencia de los datos de entrenamiento y según ella predecir cualquier dato en el futuro (Gonzales, 2019).

La regresión con vectores de soporte o SVR por su abreviación en inglés (Support Vector Regressor) entrega como resultado un número real individualizando el hiperplano que maximiza el margen, teniendo en cuenta que se tolera parte del error.



**Figura 6. Muestra gráficamente la esencia del algoritmo SVR (Fuente: González, 2019)**

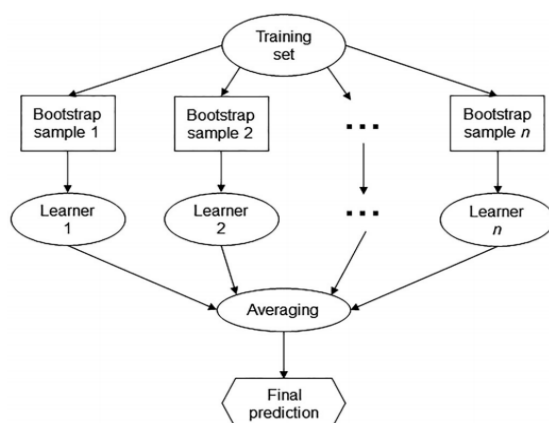
El hiperplano que se obtiene dentro de este algoritmo siempre tratará de moldear el comportamiento de los datos y esta curva siempre viene acompañada con un rango (máximo margen), tanto del lado positivo como el negativo, el cual tiene el mismo comportamiento o forma de la curva (González, 2019).

Todos los datos que se encuentren fuera del rango son considerados errores, por lo que es necesario calcular la distancia entre el mismo y los rangos. Esta distancia lleva por nombre épsilon y afecta la ecuación final del modelo (González, 2019)

- Bosques Aleatorios

El algoritmo de Bosques Aleatorios o Random Forest es un tipo de ensamble en Machine Learning en donde se combinan una multiplicidad de árboles de decisión con tal de que cada uno genere un resultado propio para el problema en estudio. Luego de ello, se realiza una votación entre los resultados obtenidos por cada árbol, en donde la respuesta final del algoritmo a la situación planteada será el resultado promedio dentro del conjunto de respuestas obtenidas (Bagnato, 2019).

Este algoritmo es del tipo supervisado y puede utilizarse tanto para clasificación de datos como para la predicción y análisis de regresión. Dentro de sus ventajas se puede mencionar que funciona adecuadamente sin la necesidad de ajustar hiperparámetros y que, al utilizar una gran cantidad de árboles de decisión, disminuye el riesgo de overfitting (tendencia a la memorización de resultados por parte de los algoritmos de inteligencia artificial). Sin embargo, también tiene desventajas, dentro de las cuales se puede mencionar que consume mucho gasto computacional al ejecutar múltiples árboles de decisión, puede requerir mucho tiempo de entrenamiento y no funciona de la mejor manera para un conjunto reducido de datos de entrenamiento.




**Figura 7. Muestra gráficamente la forma de operar del algoritmo RFR (Fuente: Marcelino, et al., 2019)**

- Regresor de Refuerzo de Gradiente

O GBR por su abreviación en inglés (Gradient Boosting Regressor), es un popular algoritmo del ML para conjuntos tabulares. Es lo suficientemente potente como para encontrar cualquier relación no lineal entre el objetivo de un modelo y los atributos explicativos. Tiene también una gran usabilidad que puede manejar valores faltantes, datos atípicos y valores categóricos de alta cardinalidad sin ningún tratamiento especial (Masui, 2022).

Este algoritmo, al igual que RFR, se basa en combinar múltiples árboles de decisión. Sin embargo, a diferencia de los bosques aleatorios, la generación de los árboles se da en forma secuencial, de forma tal que cada árbol corrige los errores de su predecesor, no como los bosques aleatorios en donde el resultado final es la respuesta más repetida o promedio. Para realizar lo anterior, cada árbol extra que se añade al modelo recibe los residuos del predecesor utilizando esa data para mejorar su propia predicción, de allí el concepto del refuerzo del gradiente.




**Figura 8. Muestra gráficamente el funcionamiento del algoritmo GBR (Fuente: AlmaBetter, 2022)**

- Redes Neuronales Artificiales

Las redes neuronales artificiales son una serie de algoritmos que buscan relaciones en un conjunto de datos. Para poder realizar lo anterior, poseen una arquitectura de nodos interconectados que le dan la apariencia de una red neuronal biológica y de la que toma su nombre (González, 2021).

En su caso más simple las ANN están formadas por tres capas de nodos, una capa de entrada, que tiene por función transmitir la información de entrada, otra capa denominada “oculta” que se preocupa de filtrar los patrones relevantes y rescatar la información de importancia y una última capa, que continúa el trabajo de la segunda realizando combinaciones y modificaciones al patrón de datos para producir la información de salida.



**Figura 9. Muestra gráficamente el funcionamiento de los algoritmos ANN (Fuente: Página web Datacentric)**


Dentro de los usos que poseen las ANN se encuentran el reconocimiento y clasificación de patrones, el procesamiento de datos y modelización y, la que resulta de mayor interés para este estudio, la predicción de sucesos y simulaciones, función que permite obtener valores de salida esperados de acuerdo con la información de entrada que recibe el algoritmo.

- Redes Neuronales Recurrentes

Las redes neuronales recurrentes o Recurrent Neuronal Network (RNN) en inglés, son una clase de algoritmo del DL para analizar datos de series temporales permitiendo tratar la dimensión de tiempo que no se considera en el algoritmo básico de las redes neuronales artificiales (Torres, 2019).

A diferencia de una neurona artificial tradicional, la neurona recurrente tiene la capacidad no solo de transmitir información hacia adelante, sino que también hacia atrás generando retroalimentación entre las mismas neuronas y las capas que posea un respectivo modelo, de allí viene el concepto de que poseen memoria.

Precisamente esta “memoria interna” es lo que hace de este tipo de redes muy adecuadas para problemas de aprendizaje automático que involucran datos secuenciales. Gracias a su memoria interna, las RNN pueden recordar información relevante sobre la entrada que recibieron, lo que les permite ser más precisas en la predicción de lo que vendrá después manteniendo información de contexto a diferencia de los otros tipos de redes que hemos visto, que no pueden recordar acerca de lo que ha sucedido en el pasado, excepto lo reflejado en su entrenamiento a través de sus pesos (Torres, 2019).



**Figura 10. Muestra gráficamente el funcionamiento de los algoritmos RNN (Fuente: Torres, 2019)**

#### 2.2.4.2 Investigaciones afines a la temática.

Durante la última década múltiples autores han dedicado tiempo a la aplicación de la inteligencia artificial en la confección de herramientas de análisis técnico para la gestión de pavimentos. En ese sentido, se han explorado diversos algoritmos, con distintos niveles de éxito, en el afán de elaborar predictores que permitan modelar el desempeño de las estructuras de pavimento en el tiempo. Dentro de los principales algoritmos revisados se encuentran la regresión de bosques aleatorios (RFR), la programación de expresión genética (GEP), los vectores de soporte de regresión (SVR), la redes neuronales artificiales (ANN) y las redes neuronales recurrentes (RNN). A continuación, se expone una tabla resumen con las principales investigaciones indagadas:

**Tabla 1. Muestra investigaciones exploradas. (Fuente: Elaboración propia)**

Referencia	Indicador a Predecir	Técnicas Utilizadas
Lin, et al., (2003)	IRI	ANN
Bianchini y Bandini (2010)	PSI	ANN
Kargah-Ostadi, et al., (2010)	IRI	ANN
Kargah-Ostadi y Stoffels (2015)	IRI	ANN, SVR
Ziarriet al (2016)	IRI	SVR
Mazari y Rodriguez, (2016)	IRI	ANN, GEP
Marcelino, et al., (2019)	IRI	RFR
Zhou, et al., (2021)	IRI	RNN
Montecinos (2022)	PCI	RFR, ANN, SVR

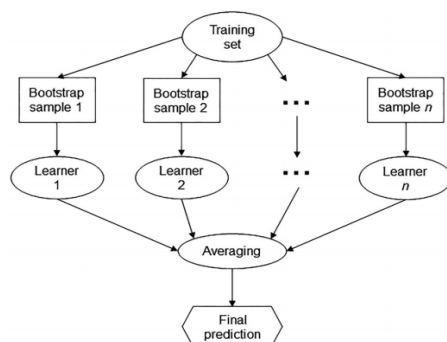
Un aspecto relevante a mencionar es que la mayoría de las investigaciones está abocada a la gestión de pavimentos interurbanos, razón por la cual el índice general a predecir es el IRI (Índice de Rugosidad Internacional), salvo por la investigación de Montecinos que enmarca su estudio en las redes de pavimentos aeroportuarios de Chile. Además de esto, la mayoría de los autores utilizan datos de la LTPP (Programa de Rendimiento de Pavimentos a Largo plazo por sus siglas en inglés) de la FHWA o poseen acceso a una base de datos organizada que les permite tener acceso a información de tránsito, deterioros superficiales, planos As Built, etc.

A continuación, se presentan los alcances de algunas de las investigaciones revisadas en donde se utiliza algunos de los algoritmos recién expuestos.

- Marcelino et al., (2019)

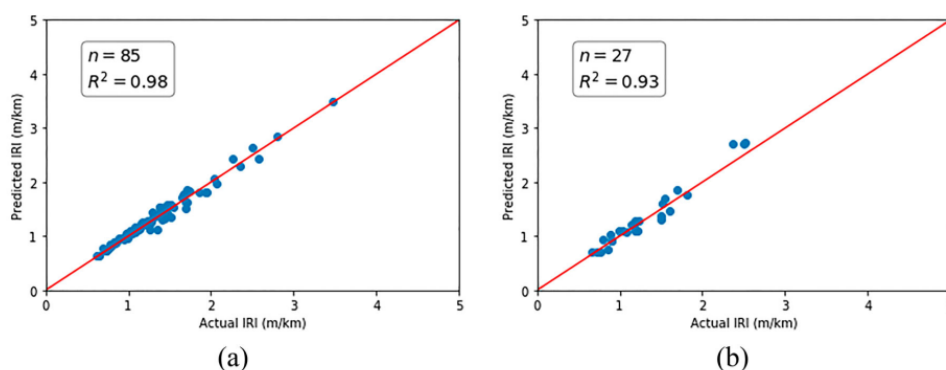
Este trabajo se enfoca en establecer un marco general para la aplicación de herramientas de inteligencia artificial en la confección de modelos de desempeño, estableciendo una metodología ejemplo en donde se elabora un modelo de desempeño prediciendo la variación del IRI en el tiempo, para un contexto de carreteras interurbanas, mediante la utilización del algoritmo Random Forest. Para ello, se vale de registros provenientes de la base de datos de rendimiento del pavimento a largo plazo (LTPP) y de una estrategia directa para el pronóstico, es decir, construye un modelo de series de tiempo separado para cada horizonte de pronóstico. Así, se logran generar modelos de desempeño con predicciones a largo plazo de 5 y 10 años. En cuanto a las variables utilizadas en la formulación de los modelos se cuentan con datos de condición estructural, rendimiento, tráfico y también climáticos.

En la ilustración siguiente se aprecia el esquema de entrenamiento para el algoritmo Random Forest utilizado, en donde los datos de entrenamiento deben pasar por cada uno de los árboles de decisión hasta lograr converger a una respuesta final.



**Figura 11. Muestra algoritmo Random Forest (Fuente: Marcelino, et al).**

Con respecto a los resultados de la investigación, los modelos lograron un buen nivel de predicción, pues la comparativa estimando el error cuadrático medio indica que el modelo a 5 años obtuvo un error de 0.064 en tanto que el modelo a 10 años obtuvo un error de 0.104. Por lo demás, los coeficientes de correlación obtenidos al contrastar los resultados del modelo con aquellos datos de campo almacenados en la base de datos LTPP son cercanos a 1, siendo más preciso el modelo de predicción generado a corto plazo (5 años), tal como se muestra en la siguiente ilustración.



**Figura 12. Muestra la comparativa entre IRI predicho e IRI actual de los modelos planteados por Marcelino, et al (Fuente: Marcelino, et al., 2019).**

Lo interesante de este reporte es que además de lograr buenos resultados para el porcentaje de datos de validación (75% de los datos para entrenamiento y 25% para validación), es que mostró también buenos resultados para la generalización, puesto que, a la hora de compararse con otros 7 modelos, resultó con mejores resultados en 5 casos, mostrando de esta forma su alto poder predictivo. Por lo demás, de los análisis de sensibilidad que se le realizaron al modelo, se da cuenta de que este es sensible a los valores de IRI previos que posea la respectiva vía, dejando como precedente de que se necesita de algún parámetro que refleje el estado actual del pavimento. También, pone la alerta de que, si bien las redes neuronales muestran un buen desempeño con los datos de entrenamiento y posterior validación, a la hora de cambiarles el contexto con nuevos escenarios, estas podrían no ser tan precisas mostrando un sobreajuste del modelo. Ante esta situación, se hace necesario combinar metodologías o utilizar algoritmos de mayor complejidad.

- Choi y Do, 2019

Predice el deterioro de pavimentos de Corea del Sur mediante el uso de datos de monitoreo con un algoritmo de red neuronal recurrente.

Con respecto a la información que se encontraba disponible para el desarrollo de los modelos destacan la longitud de sección de pavimento, información de agrietamientos, ahuellamiento, profundidad de bacheo e IRI, Tráfico Medio Diario Anual (TMDA) y cargas de un solo eje (ESAL).

En cuanto a los datos que se utilizan como variables explicativas se encuentran el TMDA, ESAL, variables climatológicas como precipitación y temperatura en tanto que las dependientes son los agrietamientos, profundidad de bacheo e IRI generando modelos distintos para cada uno de ellos.

Utiliza una red recurrente con capa LSTM con longitud de secuencia variables de entre 1 a 8 años con entrenamientos de 400 a 500 épocas y tasa de aprendizaje de 0.001

A continuación, se adjunta una imagen con los resultados de los modelos:

Clasificación		Duración de la secuencia								Mejoramiento
		1	2	3	4	5	6	7	8	
Profundidad de bacheo	RMSE	2.40	2.40	2.36	2.29	2.15	2.01	2.00	1.93	0.93
	R <sup>2</sup>	0.14	0.15	0.16	0.17	0.16	0.17	0.17	0.17	0.22
Grieta	RMSE	6.59	6.58	6.58	6.53	6.46	6.38	5.95	5.34	2.75
	R <sup>2</sup>	0.08	0.08	0.09	0.10	0.11	0.13	0.18	0.26	0.71
IRI	RMSE	0.44	0.44	0.44	0.43	0.43	0.38	0.35	0.32	0.14
	R <sup>2</sup>	0.25	0.26	0.26	0.27	0.28	0.33	0.35	0.40	0.87

**Figura 13. Muestra los resultados de precisión de los modelos (Fuente: Choi y Do, 2019)**

Al momento de revisar los resultados, se da cuenta de que estos no son del todo buenos. Los valores de RMSE son altos para profundidad de bacheo y agrietamientos, en tanto que el coeficiente de correlación es lejano a 1. El modelo con mayor nivel de precisión es el de IRI, sin embargo, tampoco supera el 0.5 del coeficiente de correlación.

De todas formas, se observa que, en lo general, mientras más información posee la secuencia de datos, mayor es la capacidad predictiva del modelo.

- Zichen Wang, et al., 2020

Elabora modelo de predicción para los pavimentos de China en contexto carretero, esto con la motivación de que “El desarrollo de la carretera se refleja no solo en la construcción, sino que también en el mantenimiento y gestión de la misma”.

Elaboran un modelo de predicción basado en la red neuronal BP, es decir, una red neuronal artificial Feed Forward multicapa basada en el algoritmo backpropagation. El modelo se construye para predecir PCI y utiliza como función de activación la función Sigmoidea.

En cuanto a las variables explicativas que utiliza se encuentran la influencia del tráfico, diseño del pavimento y aspectos climáticos.

Con respecto a la configuración del modelo neuronal, se cuenta con una red de 3 capas (entrada, oculta y salida) en donde la capa oculta posee 19 neuronas y se entrena con algoritmo Levenberg Marquardt y BP estándar.

Por último, con respecto a los resultados obtenidos, estos presentan una aceptable precisión para el año inmediatamente posterior a los datos de entrada. Sin embargo, para horizontes de predicción superiores, la precisión del modelo decae.

**Table 5** Comprehensive evaluation table of combined forecast effect

Forecast year	Model prediction			Error			Average error
	2017	2018	2019	2017	2018	2019	
Neural network model	74.7	70.3	64.4	0.0163	0.0131	-0.0092	0.0129
Markov model	74.5	70.6	65.8	0.0136	0.0173	0.0123	0.0144

**Figura 14. Muestra resultados de precisión de la investigación (Wang., et al 2020)**

Cabe destacar que estos resultados se contrastan también con un modelo Markoviano calibrado para el mismo escenario de análisis, obteniendo el modelo neuronal un mejor resultado para el año inmediatamente posterior a los datos de entrada, pero un poco menos preciso para los horizontes de tiempo mayores.

- Yang et al., 2021

Realiza una revisión sistemática de literatura para evaluar el estado del arte en la aplicación de algoritmos de IA en la gestión de pavimentos. Se examina su uso en los siguientes campos:

- Diseño de Pavimentos
- Construcción de Pavimentos
- Inspección y seguimiento
- Mantenimiento (Evaluación del desempeño, **predicción del desempeño** y planificación del mantenimiento)

Sobre la predicción del desempeño de los pavimentos, habla sobre el éxito de los modelos de IA para la predicción a corto plazo (de 1 a 5 años de horizonte de predicción). Sin embargo, es claro en señalar que para el éxito de la predicción a largo plazo es necesario utilizar algoritmos especializados en asociaciones temporales como lo son las redes neuronales recurrentes (RNN)

### 2.3 Modelos de desempeño en Chile.

Chile al ser un país en vías de desarrollo, invirtió esfuerzos en implementar sistemas de gestión de pavimentos, esto comienza a partir del año 1988 con la elaboración del sistema MANVUSIMP, el cual introduce una metodología simplificada de preparación y evaluación de programas de inversiones en conservación y rehabilitación de vías urbanas a nivel nacional (MIDEPLAN, 1996). Este sistema incorporó procedimientos definidos para la inspección de los pavimentos, tipificando deterioros específicos y expresiones que permitían evaluar la serviciabilidad de una determinada vía. Además, planteaba políticas de conservación, las cuales fueron estudiadas con criterios económicos como índices de beneficio-costos y que debían seleccionarse para aplicarse sobre una determinada vía de acuerdo con el tránsito y la serviciabilidad que esta tuviera, entre otras. La ecuación principal que permitía obtener la serviciabilidad se expone en la ecuación 1.

$$P = 5.4 - 0.1C1 - 0.1C2 - 0.3C3 \quad (1)$$

*C1: Coeficiente de Rugosidad; C2: Coeficiente de Agrietamiento*

En tanto que las políticas de conservación asociadas al índice de serviciabilidad se exponen en la figura 15:

POLÍTICAS DE CONSERVACIÓN DE PAVIMENTOS DE ASFALTO						
POLÍTICA	0	1	2	3	4	5
REHABILITACIÓN	No	No	No	Sí	Sí	Sí
Umbral P				2.5	2.0	1.5
Diseño Sn (cm.)				f(EE)	f(EE)	f(EE)
Espesor (cm.)				5	5	5
C. Estruct.				0.4	0.4	0.4
RECAPADO	No	Sí	Sí	No	No	No
Umbral IG		40%	40%			
Diseño Espesor (cm.)		3	5			
C. Estruct. (cm.)		0.3	0.3			
SELLO	Sí	Sí	Sí	Sí	Sí	Sí
Frecuencia	4	4	4	4	4	4
BACHEO						
%Sup. G (1)	5%	5%	5%	5%	5%	5%
% Máx. Acum. (2)	25%	25%	25%	25%	25%	25%

**Figura 15. Muestra la matriz de políticas de conservación para pavimentos asfálticos (Fuente: MANVU)**

Es en este sistema en donde se tiene el primer acercamiento a un modelo de desempeño en el país por medio de la estimación del índice de serviciabilidad “P”, el cual se vinculaba con la rugosidad y los deterioros superficiales para ser estimado. Posteriormente aparecen nuevos sistemas entre la década de los 90 y 2000 que vienen a ser una complementación del MANVUSIMP innovando con la inclusión de softwares y sofisticando los criterios de mantención y conservación para optimizar de mejor forma los recursos, como el sistema SAMPU y el SGCPU desarrollado en Concepción, sin embargo, no es hasta el año 2016 en que se ve orquestado un sistema de gestión que incorporara los conceptos modernos de la ingeniería vial. Este sistema es el SGPUC, el cual incorpora conceptos modernos de gestión, modelos de deterioros probabilísticos y modelos decisionales de optimización y priorización más robustos que los anteriormente mencionados (Solminihac, et al., 2018).


Para el desarrollo de los modelos de desempeño, el sistema se basa en la variación del Índice de Condición de Pavimentos Urbanos (ICPU en forma abreviada) en el tiempo en un escenario con mantenimiento y sin mantenimiento, es decir, se está en presencia de un modelo de primera y segunda fase. Para ello, utiliza matrices de transiciones de probabilidad (Modelos Markovianos), las cuales permiten predecir el estado del pavimento en una etapa futura en función del estado actual que este posea. Cabe destacar que, para estimar este índice, es necesario contar con información específica sobre los deterioros superficiales que posea el pavimento en un instante determinado, información puntual sobre el Índice de Rugosidad Internacional (IRI) y también, parámetros hidrometeorológicos como temperatura y precipitación, pues estos inciden en la estimación del ICPU en una condición futura. De esta forma, se confeccionan 8 modelos, 3 para pavimentos asfálticos y de hormigón en clima mediterráneo (zona central como referencia), 1 para pavimentos asfálticos en clima seco (zona norte) y 1 para pavimentos de hormigón en clima húmedo. A fin de cuentas, el índice ICPU se puede obtener mediante el uso de ecuaciones que ponderan los efectos de la condición de agrietamiento, rugosidad y climáticas en las ecuaciones que se muestran en la ilustración siguiente:

$$ICPU_{Asfalto,manual} = 10 - a_1GF - a_2GTR - a_3PD - a_4A - a_5B$$

$$ICPU_{Asfalto,automático} = 10 - a_6GF - a_7GTR - a_8PD - a_9A - a_{10}IRI$$

$$ICPU_{Hormigón,manual} = 10 - a_{11}GL - a_{12}GT - a_{13}PD - a_{14}E - a_{15}GEO - a_{16}SD$$

**Figura 16. Muestra las distintas expresiones para la estimación del ICPU (Fuente: Solminihac, 2018).**



**Figura 17. Muestra los modelos de desempeño elaborados para pavimentos asfálticos en clima mediterráneo (Fuente: Alelí Osorio, 2015).**

De la cronología aquí expuesta, se logra apreciar un análisis más sofisticado para el estudio del deterioro de los pavimentos en el tiempo, pues ya no solo se ve un análisis en cuanto a deterioros superficiales, sino que además se complementa con otros aspectos de interacción como lo son las solicitaciones climáticas, todo lo anterior, procesado con herramientas probabilísticas permiten estudiar y comprender el comportamiento de pavimentos urbanos de distinta materialidad en el tiempo.

## 2.4 Inferencias y análisis

De la revisión literaria, primero que todo, es necesario mencionar que no hay alcances de generación de modelos de desempeño en el país utilizando inteligencia artificial. Lo más novedoso es el trabajo desarrollado en el SGPUC en donde se desarrollan modelos de desempeño para pavimentos urbanos utilizando herramientas probabilísticas (matrices de transición de probabilidad) para su elaboración como lo son las cadenas de Markov.

En cuanto a investigaciones realizadas por académicos del área, estas se basan en la confección de modelos de desempeño para predecir la variación del Índice de Rugosidad Internacional (IRI), obteniendo, por lo general, buenos resultados al momento de combinar herramientas de inteligencia artificial considerando, además, el uso de las bases de datos LTPP para nutrir de información de entrenamiento a los algoritmos de inteligencia artificial.

Con respecto a la generalización de los modelos, existe el consenso de que se debe poseer una base de datos de entrenamiento extensa, completa y de datos fiables para que los algoritmos obtengan resultados precisos. Por lo demás, los autores llegan a conclusiones similares en cuanto a que la variable a la que son más sensibles los modelos es precisamente al dato de condición (u otro a predecir) que posea el pavimento sea tanto en su condición actual como en períodos pasados.

También, juegan un rol relevante las solicitaciones de tránsito y variables hidrometeorológicas como la temperatura y precipitación de una determinada localidad. Por último, es buen aporte a mejorar los resultados la inclusión de parámetros estructurales como el número estructural y la edad misma del pavimento.

Ahora bien, es de importancia mencionar que estos trabajos se realizan en un contexto interurbano, utilizando bases de datos de tramos de carreteras provenientes de la base de datos LTPP. Esto supone una dificultad para elaborar modelos de desempeño en el contexto urbano, en donde, a nivel de red, existen distintas materialidades en las vías (pavimentos rígidos, flexibles, mixtos, adoquines) así como también otro tipo de variables como la jerarquía de las vías, teniendo muchas veces redes primarias y secundarias que, obviamente, requieren un análisis diferenciado para elaborar modelos de desempeño.

Además, si nos situamos en el caso chileno, de elaborar modelos, estos deben tener algún punto de comparación, en ese sentido, los modelos elaborados en el SGPUC utilizan para la predicción el ICPU (índice de Condición de Pavimentos Urbanos), por lo que los modelos de desempeño debiesen adaptarse a esta métrica con tal de realizar comparaciones. La buena noticia es que los autores no descartan utilizar otras métricas que permitan evaluar el estado del pavimento. Bianchini y Bandini, 2010, generan modelos de desempeño para el Índice de Serviciabilidad de Pavimentos (PSI), por lo que el cambiar la métrica estándar utilizada no debiese suponer mayores dificultades para el desarrollo de los modelos.

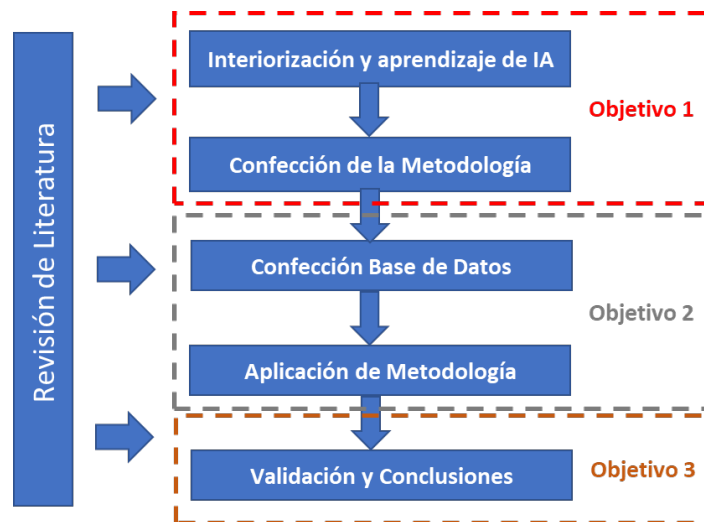
### 3 Metodología de desarrollo de la investigación.

Esclarecida la hipótesis de investigación, el problema en estudio y propuesto los objetivos, corresponde plantear la metodología para la consecución de estos. Para ello, se deben pensar una serie de actividades que permitan la consecución del objetivo general.

Con tal de lograr lo anterior, se idean una serie de fases metodológicas de forma tal que se puedan agrupar las actividades necesarias para el desarrollo de la investigación en forma secuencial y que estas mismas puedan vincularse a los objetivos específicos planteados. Las distintas fases metodológicas se plantean a continuación:

1. Interiorización y aprendizaje de conceptos de IA
2. Construcción de la metodología de modelación de desempeño de pavimentos urbanos
3. Confección y procesamiento de la base de datos experimental
4. Aplicación de la metodología
5. Validación y conclusiones

A continuación, se expone un esquema que asocia las fases metodológicas con los objetivos específicos:



**Figura 18. Muestra la vinculación entre las distintas fases metodológicas con los objetivos específicos de la investigación (Fuente: Elaboración propia).**

#### 3.1 Interiorización y aprendizaje de conceptos de IA.

Corresponde a la fase en la cual se deben adquirir los conocimientos que permitirán el correcto uso y manipulación de los algoritmos de inteligencia artificial, ya sean estos de Machine o Deep Learning. En ese sentido, es necesario la adquisición tanto de conceptos teóricos como prácticos, para lo cual se plantean las siguientes actividades:

1. Revisión de literatura afín a la Ingeniería Informática con tal de inmiscuirse en los conceptos básicos de la Inteligencia Artificial.
2. Realización de curso de ML, DL, Redes Neuronales Artificiales o similar para asimilar conceptos y familiarizarse con lenguaje y entornos de programación.

3. Vinculación de conceptos aprendidos con su uso en la gestión de pavimentos urbanos mediante procesos de revisión bibliográfica.

Es importante comprender que no se pueden utilizar los algoritmos de IA sin poseer un mínimo de conocimientos sobre ellos, puesto que, de lo contrario, se estaría atentando contra la correcta consecución de los modelos que se pretenden obtener.

### **3.2 Construcción de la metodología de modelación de desempeño de pavimentos urbanos.**

Habiendo adquirido conocimientos suficientes sobre la inteligencia artificial y sus potenciales usos en la gestión de pavimentos, se está en condiciones de plantear una metodología de modelamiento del desempeño de los firmes urbanos. Para ello, se plantean las siguientes actividades:

1. Identificación de algoritmos de IA, es decir, seleccionar puntualmente aquellos algoritmos que serán utilizados para la modelación del desempeño de pavimentos urbanos.
2. Selección de variables o atributos explicativos, lo cual corresponde a identificar cuales serán las características, parámetros o factores que explican el deterioro de la condición de los pavimentos en el tiempo.
3. Confección y procesamiento de bases de datos. Esto corresponde a delimitar un escenario específico a modelar y obtener toda la información posible referente a los atributos explicativos para dicho escenario establecido.
4. Configuración de algoritmos, es decir, iterar los distintos parámetros e hiperparámetros que poseen los distintos algoritmos con miras a obtener una predicción con un buen nivel de desempeño.
5. Predicción a corto plazo y construcción de curvas o modelos de desempeño. Corresponde a la utilización de los algoritmos para la consecución de los modelos, su uso en la predicción y posterior obtención de predicciones en cadena que permiten la obtención de la vista del desempeño del pavimento en el tiempo.
6. Análisis y validación de resultados. Incluye la comparativa de los modelos por medio de métricas de desempeño de algoritmos de IA y estadísticas generales, además de contrastar las predicciones de los modelos con datos de campo.

### **3.3 Confección y procesamiento de la base de datos experimental.**

En esta fase ya se plantean las actividades de recolección de data afín a la modelación del desempeño de los pavimentos. Cabe precisar que en la fase metodológica anterior, correspondiente al planteamiento de la metodología, ya se hace alusión a la base de datos, sin embargo, esto es dentro del contexto de dicha fase. La recolección de datos se realiza una vez de tener definida y finiquitada la fase anterior.

Aclarado lo anterior, las actividades de esta fase se exponen a continuación:

1. Selección de escenario de modelación. Pavimentos urbanos existen de distintas materialidades, distinta composición estructural, distintos usos, clasificación funcional, son afectos a distintas solicitaciones, entre otros. Ante tal contexto, el deterioro que puedan sufrir será diferente según varíen los parámetros antes mencionado, por lo que debe seleccionarse un escenario único de modelación que muestre fehacientemente el deterioro de una familia puntual de pavimentos.
2. Recolección de datos sintéticos y de campo. Definido el escenario de modelación, se debe acudir a terreno y capturar la información relevante que permita modelar la condición del pavimento, como, por ejemplo, los anchos de pista, información de los deterioros presentes en la capa de rodadura, conteos de tránsito, etc.
3. Análisis exploratorio de datos. En esta actividad se debe analizar cada uno de los datos recopilados, verificando que estos sean coherentes y se encuentren en un rango válido de aplicación.
4. Eliminación de datos atípicos. Conforme a los resultados obtenidos en la actividad 2 de esta fase, deberán eliminarse todos aquellos datos incoherentes o fuera de norma con tal de no perjudicar los resultados de los modelos de desempeño una vez se aplique la metodología.

5. División de conjuntos de entrenamiento, validación y testing. Los algoritmos de IA, en un inicio, son una caja sin ningún tipo de información. Entonces, para poder ser usados, deben entrenarse y nutrirse de la información que les permite resolver el problema. Por este motivo, se les entrega la base de datos en forma fraccionada, es decir, una parte para el entrenamiento, otra para la validación del entrenamiento y, finalmente, otra para las pruebas de desempeño de los algoritmos. En el capítulo 4 y 5 se darán más detalles de la conformación y configuración de la base de datos.

### **3.4 Aplicación de la metodología.**

las actividades de esta fase se exponen a continuación:

1. Configuración de algoritmos. Esta actividad hace referencia a la configuración inicial que se le dé a los algoritmos de inteligencia artificial. Para ello, se deberá ingresar a los algoritmos las variables explicativas preliminares que se seleccionen de las fases anteriores y, también, establecer los hiperparámetros iniciales con los que trabajarán los algoritmos. De esta forma, se podrá comenzar con el proceso iterativo de ajuste y calibración tanto de las variables explicativas como de los hiperparámetros con tal de hacer eficiente el proceso y lograr modelos con un alto nivel de precisión.
2. Entrenamiento de algoritmos. Con la configuración inicial de variables explicativas y de hiperparámetros se deberá entrenar al(los) algoritmo(s) con el 80% de los datos seleccionados para esta etapa. Para ello, se deberán aplicar técnicas de validación cruzada k-fold con repetición al conjunto de entrenamiento y de prueba, como lo plantea Montecinos, 2022.
3. Calibración de hiperparámetros y ajustes de variables. En lo que respecta a la calibración de hiperparámetros, esto dependerá del grado de subajuste o sobreajuste del modelo obtenido, entendiéndose como subajuste o underfitting la poca capacidad de generalización que tenga el modelo a la hora de predecir, en tanto que el sobreajuste o overfitting se refiere a cuando el algoritmo está sobreentrenado, aprendiendo de memoria los resultados de la fase de entrenamiento generando fallos con nuevas predicciones producto de que siempre intentará acercar los valores de predicción a los ya aprendidos.

### **3.5 Validación y conclusiones.**

las actividades de esta fase se exponen a continuación:

1. Validación y evaluación de los modelos desarrollados. Calibrados los algoritmos, se deberá analizar los modelos desarrollados con el conjunto de datos de prueba, con tal de apreciar, mediante técnicas de comparación estadística, si los resultados de predicción tienen concordancia con lo obtenido de la recolección de datos de campo.
2. Análisis y comparación de los resultados. Validados los modelos, corresponde comparar los resultados obtenidos con los distintos algoritmos evaluando su desempeño y capacidad predictiva. Además, comparar los que obtengan mejores resultados con lo existente actualmente. Es decir, contrastar con el modelo Markoviano desarrollado para el SGPUC por Osorio, 2015.
3. Elaboración de reporte y conclusiones. Analizados y comparados los casos de estudio, ya se cuenta con evidencia suficiente para establecer conclusiones que puedan aceptar o refutar la hipótesis investigativa. Realizado este análisis, se finiquita la investigación dando a conocer los resultados obtenidos a la comunidad ingenieril y científica.

## **4 Construcción de Metodología de Modelación de desempeño de Pavimentos Urbanos.**

### **4.1 Identificación de algoritmos de IA.**

La identificación de los algoritmos de inteligencia artificial procede de la revisión literaria realizada, en donde se analizan las investigaciones disponibles que hayan utilizado para su desarrollo herramientas de Machine o Deep Learning, como por ejemplo Redes Neuronales Artificiales (ANN), Regresiones de Bosques Aleatorios (RFR), entre los otros ya mencionados en el marco conceptual.

Cada uno de estos algoritmos ha sido utilizado en distintos contextos dentro de los sistemas de gestión de infraestructura vial, siendo los más comunes la elaboración de modelos de desempeño de IRI (Índice de Rugosidad Internacional) como las ya mencionadas investigaciones de Mazari y Rodríguez, 2016 y Marcelino, et al., 2019. También, se ha visto la aplicación de algoritmos de inteligencia artificial para la predicción de métricas como el PSI (Pavement Serviceability Index o Índice de Serviciabilidad del Pavimento en español) en la investigación de Bianchini y Bandini, 2010 y el PCI (Pavement Condition Index o índice de Condición del Pavimento en español) en la aplicación de modelos de desempeño para pavimentos de aeropuertos en Chile desarrollada por Montecinos, 2022. Cada una de estas investigaciones deja lecciones en cuanto al uso de variables explicativas, base de datos utilizadas, configuración de algoritmos, procedimientos de validación y, también, en cuanto a los resultados obtenidos.

En cuanto a las actividades necesarias tanto para la identificación como selección de algoritmos se encuentran las siguientes:

1. Esclarecimiento del problema a resolver: Lo que se busca es modelar el desempeño de los pavimentos urbanos, lo cual se realiza por medio del análisis de métricas específicas como lo puede ser la progresión de algún deterioro o de índices numéricos que reflejen, bajo determinadas escalas numéricas, el estado de la condición de los pavimentos. Ante tal escenario, se da cuenta de que el problema, orientado a la inteligencia artificial, trata de un problema de regresión, por lo que los algoritmos a seleccionar deben resolver problemas de esta índole.
2. Revisión del estado del arte y la práctica: Responde al análisis exploratorio de los distintos trabajos realizados, investigando acerca de las metodologías de confección de modelos de desempeño exitosamente desarrolladas y de los distintos tipos de algoritmos de inteligencia artificial existentes y que se han utilizado en el contexto de los sistemas de gestión de infraestructura vial.
3. Análisis Comparativo: Se trata de analizar las fortalezas y debilidades de las herramientas candidatas, tomando en consideración aspectos relevantes como la necesidad de datos específicos, complejidad en la modelación, gasto computacional, resultados favorables, entre otros aspectos.
4. Selección de algoritmo(s): Teniendo en carpeta el análisis comparativo y claras las virtudes y defectos de cada una de las herramientas de inteligencia artificial estudiadas, se procede a la selección de aquella(s) que sea(n) más adecuada(s) al contexto del proyecto con tal de poder aplicar la metodología experimental.

A modo de síntesis, la selección de los algoritmos se realiza una vez de comprender el problema en estudio. A partir de ello, se procede a revisar antecedentes de investigaciones realizadas por autores para explorar distintas alternativas de solución, compararlas entre ellas y seleccionar las herramientas que mejor resultados han obtenido con mira a adecuarlas al contexto particular de la investigación.

### **4.2 Selección de variables o atributos explicativos.**

Sobre este punto, lo primero a tener en consideración es entender lo que se está por ejecutar. En ese sentido, como ya ha sido mencionado, se busca elaborar una metodología para modelar el desempeño (o condición) de los pavimentos usando Inteligencia Artificial. Sin embargo, cae la interrogante de qué es un modelo, y un modelo no es más que la representación de un concepto o proceso (físico, matemático, químico, natural) mediante un conjunto de variables o atributos explicativos con tal de comprender el concepto o proceso en cuestión.

#### 4.2.1 Selección de la variable dependiente.

Teniendo interiorizado lo anterior, surge la interrogante natural de cómo modelar el desempeño de los pavimentos. Qué parámetro cuantificar para analizar su desempeño en el tiempo, es decir, seleccionar la variable dependiente.

De la revisión de literatura se dio cuenta de que las distintas investigaciones tienden a utilizar índices que describen el estado del pavimento considerando para ello aspectos como la percepción de los usuarios (PSI o Índice de Serviciabilidad del Pavimento), la rugosidad de la carpeta de rodadura (IRI o Índice de Rugosidad Internacional) o la condición de la superficie mediante el análisis del deterioro superficial que esta posea (PCI o Índice de Condición del Pavimento) (Mazari y Rodríguez 2016; Marcelino, et al., 2019; Hossain, et al., 2019; Choi y Do, 2019; Zhou, et al., 2021; Yang, et al., 2021; Haddad, et al., 2021; Montecinos, 2022).

En ese sentido, y tomando en cuenta el escenario propio de los pavimentos urbanos de Chile, lo lógico sería utilizar algún índice característico que refleje la condición de este tipo de pavimentos. Por esta razón, y dadas las últimas investigaciones realizadas en el país, se decide optar por utilizar la métrica ICPU (Índice de Condición de Pavimentos Urbanos) desarrollado por Osorio, 2013.

- **Índice de Condición de Pavimentos Urbanos de Chile (ICPU).**

El ICPU es una métrica que representa el estado del pavimento dado por el efecto combinado de los diferentes deterioros que se encuentren sobre la superficie de rodado.

El índice corresponde a un valor numérico que varía en una escala del 1 al 10, siendo 1 la peor condición y 10 la mejor. Este se asocia a una escala semántica de cinco niveles que va del Muy bueno al Muy malo, la cual es representativa de la condición general del pavimento según su importancia funcional (Osorio, 2013).

Su análisis comprende distintos tipos de materialidades tales como asfalto, hormigón y pavimentos articulados. Por ende, los deterioros que considera para su cálculo difieren según el material. Cabe destacar que la expresión matemática que permite obtener el valor del índice proviene de una regresión lineal multivariada que engloba y mancomuna los principales tipos de deterioros que afectan al pavimento urbano, según sea el caso. A continuación, se expone en la tabla 2 las distintas expresiones matemáticas que permiten obtener el valor del ICPU.

**Tabla 2. Muestra las expresiones matemáticas que permiten la obtención del ICPU (Fuente: Osorio, 2013)**

Tipo de Pavimento	Ecuación Ajustada
Asfalto	$10 - 0.038 x \%Piel\ de\ Cocodrilo - 0.049 x \%TransReflex - 0.237 x \%Baches - 0.046 x \%ParchesDeteriorados - 0.059 x Ahuellamiento$
Hormigón	$10 - 0.158 x \%G.Esquina - 0.025 x \%G.Long\_Trans - 0.053 x \%ParchesDeteriorados - 0.255 x Escalonamiento - 0.001 x \%Sellos\_Total$
Articulados	$10 - 0.394 x \%Baches - 0.015 x \%PerdSellos\_Grietas - 0.081 x \%ParchesDeteriorados$

(\*) Trans\_Reflexión es la suma de las grietas transversales y de reflexión. El ahuellamiento se ingresa en mm.

(\*\*) G.Long\_Trans es la suma de las grietas transversales y longitudinales. El escalonamiento se ingresa en mm. Sello\_Total es la suma de las longitudes de los sellos deteriorados y los desconches

(\*\*) PerSello\_Grietas es la suma de la pérdida de sellos y las grietas de la sección evaluada.

Conforme se obtiene el valor del ICPU para una determinada vía, se puede establecer una condición cualitativa y, también seguir recomendaciones de alternativas de mantenimiento, preservación o conservación según sea el grado de deterioro de la vía, su jerarquía y la materialidad que posea su carpeta de rodadura.

A continuación, se exponen las escalas cualitativas del ICPU, las cuales incluyen cinco diferentes condiciones: Muy Bueno (MB), Bueno (B), Regular (R), Malo (M) y Muy Malo (MM) (Osorio, 2013).

**Tabla 3. Escala Cualitativa Pavimentos Red Primaria (Fuente: Osorio, 2013)**

Nota	Escala Cualitativa			
	Asfalto	Hormigón	Adoquín	Todo tipo
1	MM	MM	MM	MM
2	MM	MM	MM	MM
3	MM	M	M	M
4	M	M	R	M
5	R	R	R	R
6	R	R	R	R
7	B	B	B	B
8	B	B	B	B
9	MB	MB	MB	MB
10	MB	MB	MB	MB

**Tabla 4. Escala Cualitativa Pavimentos Red Secundaria (Fuente: Osorio, 2013)**

Nota	Escala Cualitativa			
	Asfalto	Hormigón	Adoquín	Todo tipo
1	MM	MM	MM	MM
2	MM	MM	M	MM
3	M	M	M	M
4	R	R	R	R
5	B	B	B	B
6	B	B	B	B
7	B	B	MB	B
8	MB	MB	B	MB
9	MB	MB	MB	MB
10	MB	MB	MB	MB

Se expone también a continuación un cuadro de las posibles alternativas de mantenimiento, preservación y conservación que se sugieren para una vía de pavimento asfáltico en función del nivel de deterioro que ésta presente.

**Tabla 5. Muestra acciones de mantenimiento, preservación y conservación recomendadas para una vía de pavimento asfáltico en función de su ICPU (Fuente: Osorio, 2015)**

Acciones de P&M&R	Rango de aplicabilidad - UPCI		
	Red primaria	Red secundaria	Red local
Sellado de grietas	9 - 8	8.5 - 7.5	7.5 - 6
Reparación de Baches	9 - 8	8.5 - 7.5	7.5 - 6
Sello de niebla	9.5 - 8.5	-	-
Lechada asfáltica	8.5 - 7.5	-	-
Capa de sellado	8.5 - 7.5	-	-
Microsurco	8 - 7	7.5 - 6.5	-
Rejuvenecimiento funcional	8 - 6.5	7.5 - 6	7.5 - 6
Reciclaje en caliente in situ	7.5 - 5.5	7 - 5	-
Reciclaje en frío in situ	7.5 - 5.5	7 - 5	-
Renovación estructural	7 - 4.5	6.5 - 4	6 - 3.5
Reconstrucción	4.5 - 1	4 - 1	3.5 - 1

Por último, el trabajo de Osorio, 2015 culmina con el modelado del ICPU en el tiempo por medio de métodos de análisis probabilísticos como las cadenas de Markov, en donde, junto a la captura de datos de terreno de distintas vías a lo largo y ancho de Chile, se logran calibrar una serie de modelos de desempeño para distintas zonas climáticas y jerarquías de vía, las cuales son el precedente de esta investigación, la cual busca instaurar una metodología para replicar este trabajo, pero ahora usando herramientas de inteligencia artificial.

A continuación, se presentan algunos de los modelos conseguidos por Osorio, 2015. Específicamente los correspondientes a la zona climática Mediterránea.

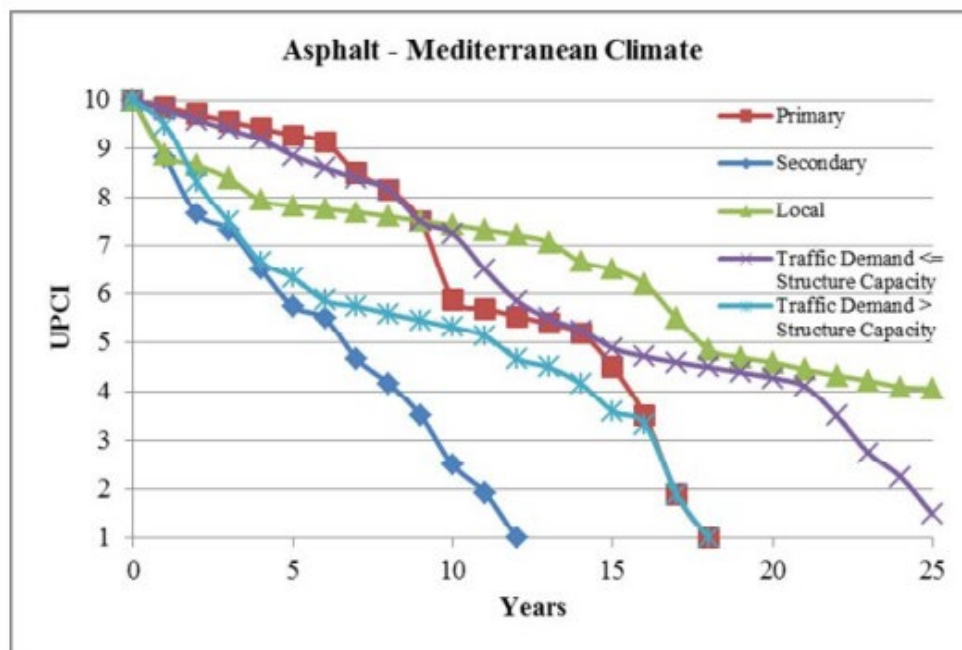


Figura 19. Muestra modelos de desempeño elaborados para la zona climática mediterránea de Chile (Fuente: Osorio, 2015)

#### 4.2.2 Selección de variables independientes o atributos explicativos.

El deterioro de los pavimentos no puede ser explicado por una sola variable, pues son muchos los factores que inciden en la progresión de este, algunos con mayor preponderancia que otros, pero que, combinados, pueden repercutir en el deterioro rápido de un pavimento (Osorio, 2015).

Ahora bien, el deterioro de los pavimentos se produce tanto por la sollicitación de tránsito para la cual presta servicio como por las inclemencias climáticas que puedan afectarlo y el cómo responda a las sollicitaciones tiene que ver con aspectos relevantes de diseño tales como características del suelo de subrasante, espesores de las distintas capas constituyentes del paquete estructural y la calidad de los materiales utilizados en su confección (Osorio, 2015; Solminihaç, et al., 2018; Hossain, et al., 2019).


Como se logra apreciar, son múltiples los factores, variables o atributos que logran explicar la progresión del deterioro en el tiempo, por lo que se deben plantear criterios de selección para trabajar con un número manejable de variables que sean realmente representativas del escenario a modelar.

##### 4.2.2.1 Selección Preliminar.

En primera instancia, se puede realizar una selección preliminar que englobe las variables incidentes que más se repiten en el estado del arte y la práctica conforme a las investigaciones que desarrollan un experimento similar.

Con lo anterior en contexto, tienden a utilizarse como variables explicativas para la progresión de métricas de desempeño aspectos como el tránsito (caracterizado como TMDA o Ejes Equivalentes), parámetros estructurales como el Número estructural del Asfalto u espesor de la carpeta, la edad del pavimento, aspectos climáticos como precipitación, temperatura, heladas y nieve y, por último, series de tiempo de alguna métrica de condición, tránsito o clima. Esto se ve refrendado en una investigación de revisión del estado del arte, en la cual se reafirma el uso de estos atributos como los principales utilizados para realizar predicciones sobre el desempeño de los pavimentos (Yang, et al., 2021).

En general, los distintos autores tienden a utilizar como atributos explicativos sollicitaciones ligadas al tránsito, clima y aspectos ligados al proceso constructivo como espesores de capas estructurales, tal como se muestra en la figura X.



**Figura 20. Muestra principales atributos explicativos utilizados para modelar la progresión del deterioro en pavimentos (Fuente: Elaboración Propia)**

Ahora bien, distintos autores han profundizado este análisis y, además de incorporar las variables intuitivas, adicionan al análisis otros aspectos ligados a la historia de los pavimentos. En ese sentido, se incorporan antecedentes del deterioro de los pavimentos como lo puede ser, en el caso de pavimentos asfálticos, el porcentaje de agrietamiento presente, presencia o no de baches, ahuellamiento, entre otros (Paytán, 2018; Choi y Do, 2019; Zhou, et al., 2021).

Por otra parte, algunos autores está de acuerdo en considerar la historia de los pavimentos, pero en una única métrica que represente esta historia. Bajo ese aspecto, hace sentido lo planteado por Osorio, 2015 cuando señala que “los distintos factores que inciden en el deterioro como agrietamientos, depresiones, baches o la rugosidad suelen acoplarse en un índice combinado que refleje su estado de deterioro actual”. De esta forma, autores como Mazari y Rodriguez, 2016; Marcelino, et al., 2019; Wang, et al., 2020;

Montecinos, 2022 utilizan la historia de condición aunada en una métrica característica como lo puede ser el PCI, PSI o IRI según sea el caso.

Por último, algunos autores aprovechan las bondades de los algoritmos de inteligencia artificial para procesar variables categóricas incorporando aspectos como clasificación funcional de vías, zonas climáticas, geográficas o la materialidad (Marcelino, et al., 2019; Hossain, et al., 2019; Montecinos, 2022).

A modo de resumen, en la tabla siguiente se expone el tipo de atributo explicativo y la serie de datos que se podría llegar a utilizar en función de los datos disponibles

**Tabla 6. Muestra los tipos de atributos explicativos y los tipos de datos que se pueden obtener como característica representativa de ellos (Fuente: Elaboración Propia)**

<b>Tipo de Atributo Explicativo</b>	<b>Tipo de dato a utilizar</b>
<b>Estructura de Pavimento</b>	Espesores de capas estructurantes, Número Estructural de carpeta, Módulo Resiliente, Módulo de Reacción de la subrasante
<b>Solicitaciones de Tránsito</b>	Tránsito Medio Diario Anual, Flujos vehiculares, Ejes Equivalentes, Peso de eje
<b>Solicitaciones Climáticas</b>	Temperatura ambiente, Precipitación Anual, Información de ciclos de hielo y deshielo
<b>Historial de Condición</b>	Porcentaje o Área agrietada, Ahuellamiento, Rugosidad, Métricas Combinadas (PSI, PCI, IRI, entre otros, por ejemplo)
<b>Variables Categóricas</b>	Clasificación funcional, zona climática, zona geográfica, materialidad

Un aspecto a tener en consideración sobre los atributos explicativos es su naturaleza, ya sea esta dinámica o estática. Esto lo plantea Marcelino, et al., 2019. Puesto que el deterioro de los pavimentos es un proceso incremental que guarda estrecha relación con el historial previo. De esta forma, se sienta el precedente de que, para una adecuada modelación, es importante considerar algunos de los atributos explicativos como variables dinámicas mediante la interacción de series temporales que contemplen información de, al menos, un ciclo previo de condición, tránsito o clima (según sean los atributos explicativos seleccionados para el modelo).

Dicho lo anterior, la tabla 7 puede complementarse de la manera siguiente:

**Tabla 7. Muestra los atributos explicativos y su naturaleza (Fuente: Elaboración Propia)**

<b>Tipo de Atributo Explicativo</b>	<b>Tipo de dato a utilizar</b>	<b>Naturaleza del atributo</b>
<b>Estructura de Pavimento</b>	Espesores de capas estructurantes, Número Estructural de carpeta, Módulo Resiliente, Módulo de Reacción de la subrasante	Estático
<b>Solicitaciones de Tránsito</b>	Tránsito Medio Diario Anual, Flujos vehiculares, Ejes Equivalentes, Peso de eje	Dinámico

Tipo de Atributo Explicativo	Tipo de dato a utilizar	Naturaleza del atributo
Solicitaciones Climáticas	Temperatura ambiente, Precipitación Anual, Información de ciclos de hielo y deshielo	Dinámico
Historial de Condición	Porcentaje o Área agrietada, Ahuellamiento, Rugosidad, Métricas Combinadas (PSI, PCI, IRI, entre otros, por ejemplo)	Dinámico
Variables Categóricas	Clasificación funcional, zona climática, zona geográfica, materialidad	Estático

#### 4.2.2.2 Selección Definitiva.

Con la selección preliminar de atributos explicativos puede realizarse todo el proceso de elaboración de modelos, incluso se pueden obtener las predicciones a corto y largo plazo de la variable dependiente con un nivel de precisión que puede ser o no aceptable. Si embargo, como todo en la vida, el modelo que se desarrolle puede ser perfectible.

Por este motivo, es necesario realizar un estudio de sensibilidad que mida la importancia de cada variable independiente o atributo explicativo, para optimizar así el número de variables utilizadas y seleccionar las definitivas que mejor se adecúan al contexto del problema.

Dicha selección debe realizarse una vez estudiada las fuerzas de correlación entre los atributos explicativos y la variable dependiente, para lo cual se recomiendan las siguientes pruebas:

- Prueba Anova F-value

El método de valor F de ANOVA estima el grado de linealidad entre la característica de entrada (es decir, el predictor) y la característica de salida. Un valor F alto indica un alto grado de linealidad y un valor F bajo indica un grado bajo de linealidad. La principal desventaja de usar el valor F de ANOVA es que solo captura las relaciones lineales entre la característica de entrada y salida. En otras palabras, el valor F no puede detectar ninguna relación no lineal (Allende, 202X).

- Prueba Información Mutua

La información mutua (MI) mide la dependencia de una variable a otra cuantificando la cantidad de información obtenida sobre una característica, a través de la otra característica. La información mutua se calcula entre dos variables y mide la reducción de la incertidumbre para una variable dado un valor conocido de la otra variable. MI es simétrico y no negativo, y es cero si y solo si la característica de entrada y salida son independientes. Por ejemplo, si X e Y son independientes, entonces conocer X no da información sobre Y y viceversa, por lo que su información mutua es cero. A diferencia del valor F de ANOVA, la información mutua puede capturar relaciones no lineales entre la característica de entrada y salida (Allende, 202X).

En la teoría de la probabilidad y la teoría de la información, la información mutua (MI) de dos variables aleatorias es una medida de la dependencia mutua entre las dos variables. Más específicamente, cuantifica la "cantidad de información" (en unidades como shannons, comúnmente llamados bits) obtenida sobre una variable aleatoria mediante la observación de la otra variable aleatoria. El concepto de información mutua está íntimamente ligado al de entropía de una variable aleatoria, una noción fundamental en la teoría de la información que cuantifica la "cantidad de información" esperada contenida en una variable aleatoria (Allende, 202X).

Cada una de estas pruebas puede realizarse en un entorno de programación de Python ® utilizando la librería Scikit Learn (Scikit Learn, 2011).

Por último, realizadas las pruebas y estudiadas las pruebas de fuerza de correlación (lineal o no lineal) de los atributos explicativos con la variable dependiente, se debe utilizar un selector de características, específicamente el denominado “SelectKbest” utilizado como método de filtro la prueba Anova o de Información Mutua para seleccionar solamente “k” atributos explicativos para que sean los atributos finales del modelo.

La cantidad “k” de atributos a considerar es netamente arbitraria y dependen del criterio del modelador considerando aspectos de rendimiento como tiempo de procesamiento, capacidad de procesamiento o complejidad del modelo a obtener (Scikit Learn, 2011).

### **4.3 Confección y procesamiento de bases de datos.**

Un aspecto clave para el funcionamiento de los algoritmos de Inteligencia Artificial son los datos que se utilizan para entrenar y calibrar modelos, es decir, la utilización de ejemplos o referencias que se le entregan a un determinado algoritmo para que calibre sus parámetros e hiperparámetros y así pueda realizar adecuadamente las predicciones que de él se esperan.

Lo anterior resume el paradigma de “Aprendizaje Supervisado”, el cual es un tipo de aprendizaje en IA donde los algoritmos trabajan con datos etiquetados (labeled data), intentando encontrar una función que, dadas las variables de entrada (input data), les asigne una etiqueta o valor de salida adecuado (Recuero De los Santos, 2021). El algoritmo se entrena entonces con un “histórico” de datos y así aprende a asignar la etiqueta o valor de salida adecuado a un nuevo valor, es decir, predice el valor de salida (Simeone, 2018).

Con lo anterior en contexto, se comprende la importancia de contar con una base de datos apropiada para entrenar de buena forma los algoritmos, sin embargo, ¿Cuánto es la cantidad de datos mínima que se requiere para entrenar algoritmos de Inteligencia Artificial?

Sobre un mínimo de datos no existe un real consenso, lo único que si se sabe con certeza es que mientras más datos mejor. A raíz de lo mismo, las distintas investigaciones realizadas se apoyan en bancos de datos existentes contando así con amplia información histórica que permite tener una multiplicidad importante de información para nutrir una base de datos de entrenamiento. Es así como las investigaciones de Mazari y Rodríguez, 2016; Marcelino, et al., 2019; Hossain, et al., 2019; Zhou, et al., 2021, entre otras, se valen del banco de datos “Long Term Pavement Performance” (LTPP) de la Federal Highway Administration (FHWA) para realizar sus experimentos de calibración de modelos contando así con millares de datos de entrenamiento y validación.

En el caso urbano Chileno no existe un banco de datos que permita adquirir información histórica sobre la condición de los pavimentos, es más, los estudios provenientes de la Pontificia Universidad Católica de Chile, desde dónde emana la métrica de análisis ICPU data del año 2015, y todavía no logra masificar ni estandarizar su métrica como herramienta de gestión en las distintas agencias viales encargadas de la manutención de los pavimentos urbanos en Chile, por lo que la confección de la base de datos para la consecución de los modelos supone un gran problema.

Ante tal situación, el mínimo de datos requeridos cobra una relevancia mayúscula. Sin embargo, revisando la literatura existente se encuentran una consideración que entrega una certera referencia que indica que el mínimo de datos de entrenamiento de algoritmos para algoritmos de Inteligencia Artificial sea, al menos, 10 veces la cantidad de variables que explican la fenomenología (Chicco, 2017). Dicha recomendación también es seguida por Montecinos, 2022, quien tampoco se vale del banco de datos LTPP, pues sus modelos se calibran para predecir el desempeño de la red de pavimentos aeroportuarios de Chile, contando con información propia de la Dirección de Aeronáutica Civil.

#### **4.3.1 Confección.**

Teniendo en cuenta las consideraciones anteriores y también las limitaciones que supone el contexto urbano Chileno, se debe confeccionar una base de datos apropiada y, para ello, se deberán tomar en cuenta las siguientes actividades:

1. Definir el escenario a modelar: Materialidad del pavimento, zona climática, tipo de jerarquía.

2. Definir tipos de datos a recolectar: En función de los atributos explicativos, seleccionar el tipo de dato a recolectar, por ejemplo, espesor de carpeta asfáltica, módulo resiliente, ICPU actual, TMDA, etc.
3. Toma de datos: Hace referencia a la captura de datos de cada uno de los atributos explicativos seleccionados, la cual puede ser de campo, sintética o combinación de ambas.
4. Análisis Exploratorio de datos: Analizar cada uno de los datos recopilados, verificando que estos sean coherentes y se encuentren en un rango válido de aplicación. A modo de ejemplo, si la métrica de condición a utilizar fuese el ICPU, este oscila entre 1 y 10, por lo que cualquier valor fuera de este rango debiese ser desestimado.
5. Eliminación de datos atípicos: Conforme a los resultados obtenidos en la actividad anterior, deberán eliminarse todos aquellos datos incoherentes o fuera de norma con tal de no perjudicar los resultados de los modelos de desempeño una vez se aplique la metodología.

#### 4.3.2 Procesamiento.

El procesamiento hace referencia a como se debe trabajar la base de datos de forma tal que los datos sean admitidos por los algoritmos de Inteligencia Artificial. En ese sentido, la mayoría de los algoritmos de IA se encuentran preconfigurados en la librería de codificación Python® Scikit Learn, por lo que se recomienda trabajar en dicho entorno programable por medio plataformas como Google Colab, Jupyter Notebook o Kaggle.

Teniendo en cuenta lo anterior, se recomienda seguir los siguientes pasos para procesar la base de datos:

1. Generar Dataframe: Incluir en el variables dependientes e independientes y procesarlo mediante la librería Pandas.
2. Procesar Variables Categóricas: Mediante técnica “OneHotEncoder”, la cual transforma las variables categóricas a una matriz numérica uni-calificada, es decir con valor 1 si es que el atributo corresponde y 0 si es que no (Scikit Learn, 2011). De esta forma dichas características pasan de ser un script a un atributo numérico procesable por los algoritmos de inteligencia artificial.
3. Normalizar los datos: Habiendo completado los pasos anteriores, se procede a normalizar los datos. Esto debe realizarse para que todas las variables se muevan dentro de un rango definido y similar, a la misma escala. Así, se impide que alguna variable tome mayor preponderancia por el hecho de encontrarse en una escala numérica diferente. Para normalizar los datos se recomienda el uso de la herramienta MinMaxScaler() de Scikit Learn, esto con el objetivo de que todas las variables oscilen entre 0 y 1 (Fausset, 1994; Montecinos, 2022).

Habiendo realizado todo lo anterior, se debiese tener una base de datos adecuada para el entrenamiento, validación y testeo de los algoritmos.

#### 4.4 Configuración de algoritmos.

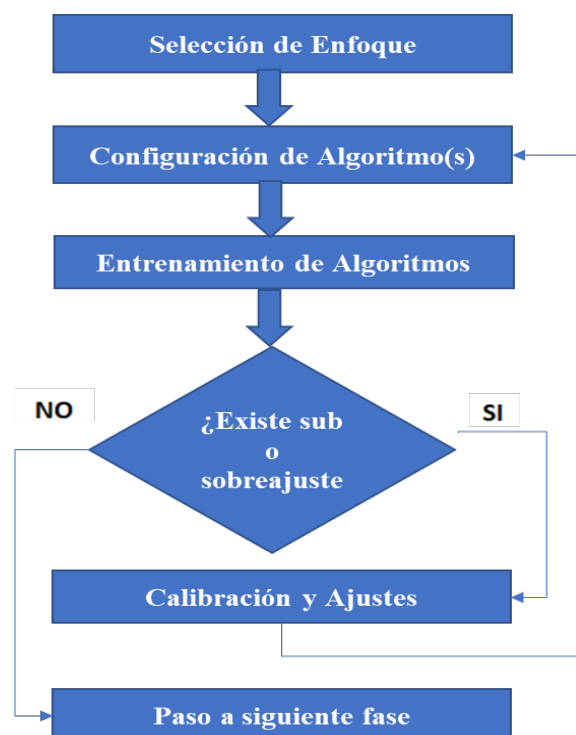
Como se mencionó anteriormente, los algoritmos se encuentran preconfigurados en la librería Scikit Learn. Sin embargo, cada algoritmo posee hiperparámetros que deben ser seteados para que puedan generar la predicción deseada de la variable dependiente. A continuación se detallan los hiperparámetros a configurar por cada algoritmo.

1. Algoritmo Random Forest Regressor: Se debe configurar los hiperparámetros “N estimators” o cantidad de árboles del bosque junto con “Min Samples leaf” o mínima cantidad de muestras para una división.
2. Algoritmo Gradient Boosting Regressor: Se debe configurar solamente el hiperparámetro “N estimators” o cantidad de árboles concatenados.
3. Algoritmo Support Vector Regressor: Se debe configurar su Kernel o núcleo pensando en si debe procesar datos lineales o no lineales, la constante “C” que determina el equilibrio entre la regularidad de la función y la cuantía hasta la cual se toleran desviaciones mayores a las banda de soporte del algoritmo. También, debe estimarse el hiperparámetro “Epsilon”, el cual controla el error cometido por la función de regresión al aproximar a las bandas o vectores de soporte.

4. Algoritmo Artificial Neuronal Network: Este algoritmo de inspiración biológica posee una mayor cantidad de hiperparámetros, consecuente con ser también un algoritmo de mayor complejidad. En ese sentido, los hiperparámetros a tener en consideración son el número de capas ocultas, número de neuronas presentes por capa, función de activación a utilizar por cada neurona, el “Learning Rate” o tasa de aprendizaje, la función de pérdida a utilizar, el “Batch Size” o tamaño de lote y las épocas de entrenamiento.
5. Algoritmo Recurrent Neuronal Network: También es un algoritmo de inspiración biológica y contempla los mismos hiperparámetros que las Artificial Neuronal Networks.

La correcta selección de hiperparámetros corresponde a un proceso iterativo en el cual se selecciona un set de hiperparámetros, se entrenan los algoritmos con la base de datos de entrenamiento y se evalúa el desempeño de los mismos. Si este es bueno, es decir, no existe ni sub ni sobreajuste, se puede sentenciar de que se ha encontrado el set idóneo de hiperparámetros. Caso contrario, estos deben modificarse y configurar los algoritmos nuevamente.

La figura 21 muestra este proceso iterativo:



**Figura 21. Muestra ciclo iterativo para la configuración de algoritmos de Inteligencia Artificial (Fuente: Elaboración Propia)**

En el párrafo anterior se mencionaron los conceptos de sub y sobreajuste de modelos ¿A qué se refiere?


#### 4.4.1 Subajuste o Underfitting.

Hace referencia a la poca capacidad de generalización que pueden tener los modelos a la hora de predecir su variable dependiente. Esta condición tiende a generarse cuando se poseen pocos datos de entrenamiento, por lo que los algoritmos no son capaces de aprender el patrón a predecir generando una predicción pobre.

#### 4.4.2 Sobreajuste o Overfitting.

Se refiere a cuando el algoritmo está sobreentrenado, aprendiendo de memoria los resultados de la fase de entrenamiento generando fallos con predicciones en base a datos que el algoritmo nunca ha visto, producto de que siempre intentará acercar los valores de predicción a los ya aprendidos o vistos por el algoritmo.

A continuación, en la figura 22 se entrega un diagrama que ilustra gráficamente los conceptos de subajuste o underfitting y sobreajuste o overfitting.



**Figura 22. Muestra diagrama ilustrativo de los conceptos de subajuste o sobreajuste (Fuente: Aprende Machine Learning).**

#### 4.5 Entrenamiento, Validación y Testeo.

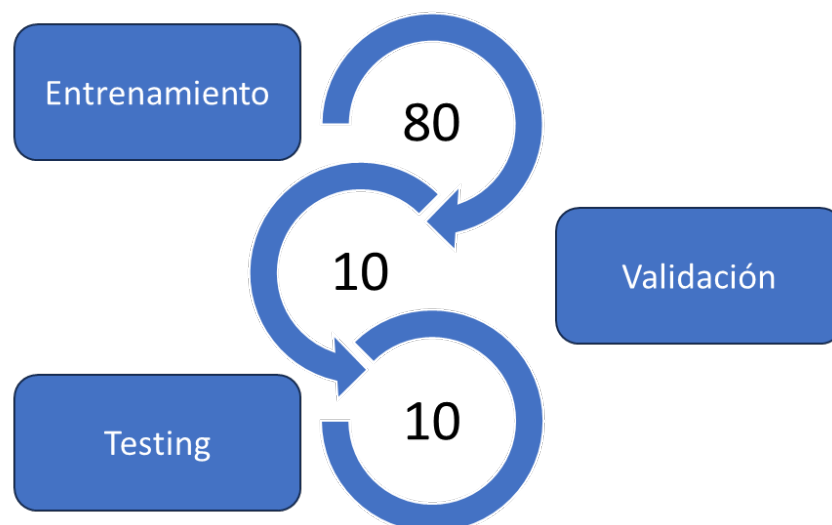
Una vez confeccionada y procesada la base de datos y configurados también los algoritmos, procedemos a la fase de entrenamiento y validación de los algoritmos.

##### 4.5.1 Entrenamiento.

Para realizar el entrenamiento de los algoritmos, se debe trabajar con una fracción de la base de datos confeccionada dejando un remanente para las pruebas de testeo y validación. Esta subdivisión de conjuntos puede realizarse mediante la librería Scikit Learn mediante la función `TrainTestSplit()` (Scikit Learn, 2011).

En cuanto a la proporción de los conjuntos de entrenamiento, validación y testeo. Esta es más bien arbitraria, es decir, a gusto del modelador. Sin embargo, la mayoría de las investigaciones utiliza un 80% para entrenamiento y 20% para validación y testeo repartiéndose uniformemente en 10 y 10% respectivamente (Mazari y Rodríguez; Marcelino, et al., 2019; Hossain, et al., 2019; Wang, et al., 2021; Montecinos, 2022).

En la figura 23 se muestra un esquema ilustrativa de la subdivisión de la base de datos.



**Figura 23. Muestra subdivisión de la base de datos en los conjuntos de entrenamiento, validación y testeo (Fuente: Elaboración Propia)**

Resuelto lo anterior, cada algoritmo se entrena mediante el uso de la función fit(), la cual induce el entrenamiento con el conjunto preparado para dicho proceso.

#### 4.5.2 Validación y Testeo.

Para lo que es la validación y testeo existen dos procedimientos.

##### 4.5.2.1 Validación y Testeo Tradicional.

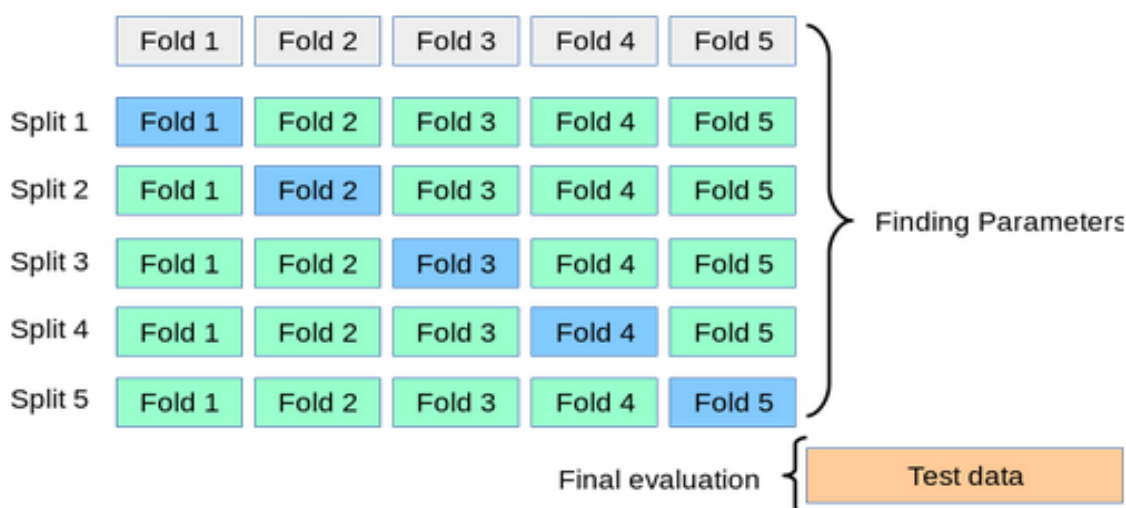
El tradicional, que involucra evaluar directamente el modelo entrenado con el 20% remanente de la base de datos destinado exclusivamente para este apartado, en donde se contrastan las predicciones de la variable dependiente del modelo recién entrenado con el valor “real” o “correcto” que debiese tomar.

Un modelo con el entrenamiento apropiado sería capaz de predecir adecuadamente el valor de la variable dependiente con un bajo nivel de error, pensando en que el 20% de datos destinado para ello fue seleccionado en forma aleatoria desde la muestra de datos original.

##### 4.5.2.2 Validación y Testeo mediante Validación Cruzada K-fold.

Este método difiere del tradicional en el sentido de que se utiliza todo el set de datos tanto para entrenamiento como para validación y testeo. Su lógica radica en subdividir la base de datos original en “k” conjuntos o “Splits”. De esta manera, se generan “k” fases de entrenamiento y validación distintos en donde “k-1” conjunto de datos se utiliza para entrenamiento y 1 para las pruebas de validación y testeo (Scikit Learn, 2011).

En la figura 24 se muestra ilustrativamente este proceso considerando un número “k” igual a 5



**Figura 24. Muestra esquema ilustrativo del proceso de Validación Cruzada K-fold (Fuente: Scikit Learn, 2011).**

Esta forma de realizar la validación resulta más robusta puesto que examina todos los posibles casos de predicción incluyendo aquellos que se le facilitan a los algoritmos como también los que resultan de una dificultad mayor, poniendo a prueba la real capacidad de generalización del modelo configurado (Scikit Learn, 2011; Montecinos, 2022).

##### 4.5.2.3 Métricas de evaluación.

En este punto se ha mencionado de validación y testeo examinando el error que comete un respectivo algoritmo a la hora de predecir la variable dependiente, es decir, poner a prueba el desempeño del modelo configurado. Sin embargo ¿Cómo medir ese desempeño?

Para medir el desempeño de modelos regresivos que se configuran mediante herramientas de Inteligencia Artificial existen distintas métricas de evaluación, dentro de las cuales popularmente se utilizan el “Error Medio Absoluto” (MAE), La “Raíz del Error cuadrático Medio” (RMSE) y, en el caso de los algoritmos de Machine Learning, se tiene también el Accuracy o Score. Estas métricas se repiten

en cada una de las investigaciones revisadas en el proceso de revisión de literatura y que se expusieron también en la tabla 1.

A continuación, se exponen las fórmulas representativas de cada métrica

$$MAE = \frac{1}{n} \sum_{j=1}^n \|y_j - \hat{y}_j\| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (3)$$

$$Accuracy, Score = \frac{Predicción\ Correcta}{Total\ Casos} * 100\% \quad (4)$$

En el caso de las métricas expuestas en las ecuaciones (2) y (3), representan directamente el error que el modelo comete a la hora de predecir la variable dependiente, por ende, mientras más tendiente a cero su valor, se habla de una mejor capacidad predictiva del modelo. En tanto que para el caso de la Accuracy o Score, trata de un porcentaje que examina el grado de acierto que tiene el modelo por sobre la totalidad de casos, por ende, mientras más próximo a 100 (caso porcentual) o a la unidad (caso cociente), se habla de un mejor desempeño del modelo configurado.

#### 4.6 Predicción a corto plazo y construcción de curvas de desempeño.

Habiendo cumplido con el proceso iterativo de configuración de algoritmos, entrenamiento y validación y testeo de los modelos configurados, resta sencillamente la aplicación de los modelos para la predicción de la variable dependiente ca corto y largo plazo.

##### 4.6.1 Predicción a corto plazo.

Trata de entregar a un modelo configurado un vector de atributos para que prediga su valor para la variable dependiente. Cabe destacar que la cantidad de atributos dependerá de los decidido y seleccionado en las fases previas de la metodología.

En la figura 25 se expone el esquema ilustrativo para la predicción.

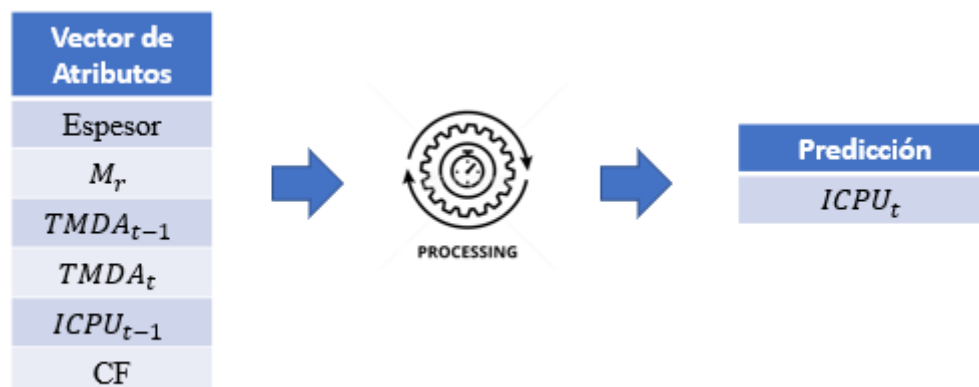



Figura 25. Muestra esquema ilustrativo para la predicción de la variable dependiente a corto plazo (Fuente: Elaboración Propia)

Para el caso de la predicción propia, que en este caso se muestra para la predicción de ICPU de un ciclo “t” considerando información dinámica de un ciclo previo “t-1”, se habla de una predicción de estilo directo, puesto que el valor entregado por el algoritmo es un salto directo al ciclo siguiente (Marcelino, et al., 2019).

#### 4.6.2 Predicción a largo plazo.

Persigue la misma lógica que la predicción a corto plazo, solo que en un ciclo iterativo en donde el vector de atributos se modifica en forma recursiva con el valor de predicción que entrega el modelo para así predecir el valor siguiente.

En la figura 26 se muestra ilustrativamente dicho proceso recursivo.

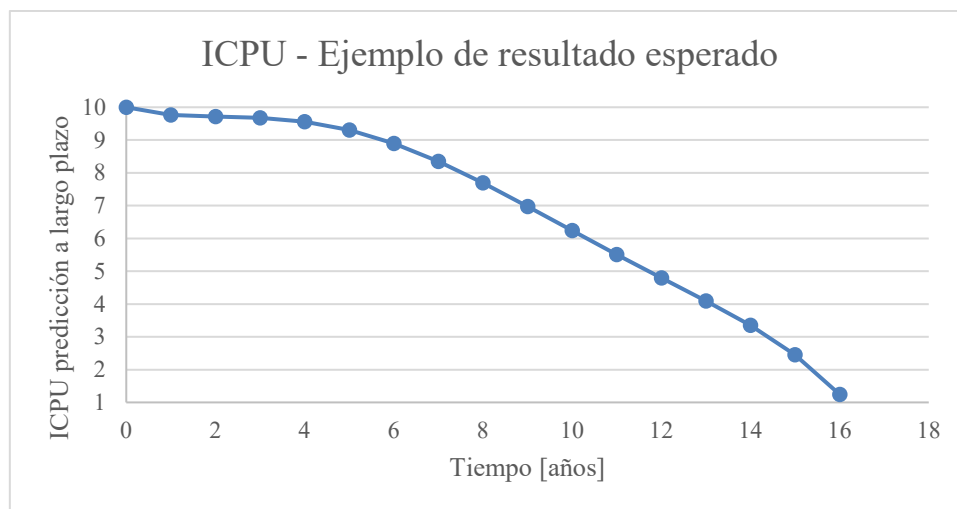


**Figura 26. Muestra esquema ilustrativo para la predicción de la variable dependiente a largo plazo (Fuente: Elaboración Propia)**

En el caso de la predicción a largo plazo, se habla de una predicción indirecta, puesto que el modelo utiliza los resultados de sus propias predicciones para entregar la información de los ciclos siguientes (Marcelino, et al., 2019).

#### 4.6.3 Construcción de Modelos o Curvas de Desempeño.

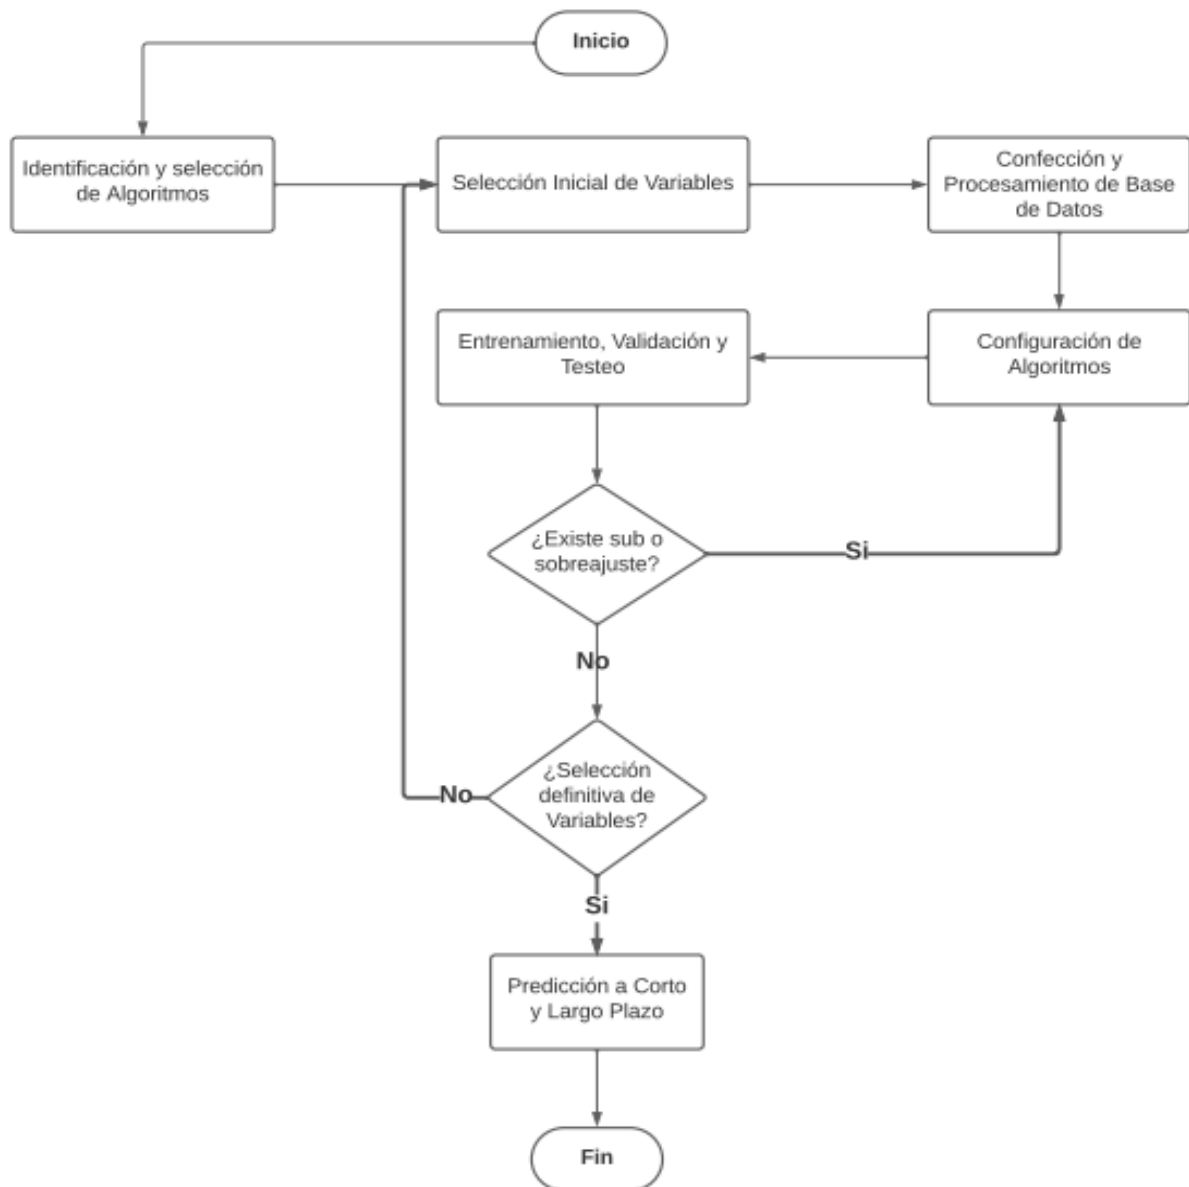
La predicción a largo plazo es el paso esencial para la construcción de los modelos de desempeño, puesto que la curva de desempeño viene representada por dichas predicciones en función de su ciclo temporal predictivo. Es decir, conociendo la predicción y su correspondiente instante temporal, se tiene la información suficiente para construir gráficamente dicha curva.



**Figura 27. Muestra ejemplo de resultado esperado para Modelo o Curva de Desempeño (Fuente: Elaboración Propia)**

#### 4.7 Diagrama de Flujo ilustrativo.

Por último, habiendo explicado cada uno de los pasos que conlleva la metodología para modelar el desempeño de pavimentos urbanos, se expone un diagrama ilustrativo con el tipo de secuencia que sigue cada una de las etapas metodológicas planteadas.



**Figura 28. Muestra Diagrama de Flujo asociado a la metodología planteada (Fuente: Elaboración Propia)**

En el se da cuenta que tanto el proceso de configuración de algoritmos, es decir, el ajuste de los hiperparámetros de cada uno de los algoritmos como la selección definitiva de variables o atributos explicativos son procesos iterativos que se van reajustando en la medida que se realizan las pruebas de entrenamiento, validación y testeo de cada uno de los algoritmos seleccionados.

## 5 Aplicación de la Metodología a mini red de pavimentos urbanos.

Habiendo explicado cada uno de los pasos o etapas para la modelación del desempeño de pavimentos urbanos, corresponde comenzar con la aplicación de la metodología para analizar su efectividad y eficacia en la tarea que se le encomienda.

Para ello, se seguirá cada uno de los pasos planteados para modelar el desempeño de una mini red de pavimentos urbanos que contempla vías y avenidas de las comunas de Estación Central, Macul, Maipú y Ñuñoa de la Región Metropolitana de Santiago de Chile.

La aplicación de la metodología a la consecuente base de datos tiene el objetivo de examinar funcionamiento, bondades y desventajas del enfoque de modelación.

### 5.1 Selección de algoritmos.

Luego de revisada y sintetizada las distintas investigaciones afines a la temática y enfoque de modelación, se opta por utilizar los siguientes algoritmos:

**Tabla 8. Muestra los algoritmos seleccionados para la aplicación de la metodología**

<b>Algoritmo</b>	<b>Sigla (Naturaleza)</b>
<b>Random Forest Regressor</b>	RFR (Machine Learning)
<b>Gradient Boosting Regressor</b>	GBR (Machine Learning)
<b>Support Vector Regressor</b>	SVR (Machine Learning)
<b>Artificial Neuronal Network</b>	ANN (Deep Learning)
<b>Recurrent Neuronal Network</b>	RNN (Deep Learning)

Los algoritmos RFR, SVR, ANN y RNN han sido ampliamente utilizados para la modelación del desempeño de pavimentos, sea este desempeño representado por IRI, PSI o PCI (Lin, et al., 2003; Bianchini y Bandini 2010; Kargah-Ostadi y Stoffels 2015; Mazari y Rodriguez, 2016; Marcelino, et al., 2019; Zhou, et al., 2021; Montecinos, 2022).

El caso del algoritmo GBR es distinto, puesto que no se observó su utilización en problemas regresivos asociados a la modelación del desempeño de pavimentos. Sin embargo, su uso es una expresa recomendación del Doctor Héctor Allende Cid, quien se desempeña como académico auxiliar de la Pontificia Universidad Católica de Valparaíso de Chile. Esto producto de que el algoritmo GBR funciona bajo la misma lógica del algoritmo RFR, es decir, aunando arboles de decisión. Sin embargo, con la diferencia de que el algoritmo GBR le entrega los residuales al árbol subsecuente, minimizando de esta forma el error cometido, no como el algoritmo RFR que sencillamente promedia el resultado de cada árbol de decisión.

### 5.2 Selección preliminar de variables.

#### 5.2.1 Variable dependiente.

Como ya se mencionó en el capítulo 4 de este trabajo, al estar inmersos en el análisis de pavimentos urbanos de Chile, se utilizará como métrica del deterioro de los pavimentos el Índice de Condición de Pavimentos Urbanos (ICPU) desarrollado por Osorio, 2014.

## 5.2.2 Variables Independientes.

Para el caso de las variables independientes, se toman en consideración los siguientes atributos explicativos:

- Estructura del pavimento: Considerando como atributos medibles el espesor de la carpeta de rodadura y el módulo resiliente de la subrasante
- Historial de condición previo: Considera la última medición de ICPU previo al ciclo a estimar
- Historial de tránsito: Considera datos de TMDA del ciclo previo a estimar y el correspondiente al mismo ciclo de estimación de la variable dependiente.
- Clasificación Jerárquica: Comprende una variable categórica que identifica el uso que presta la vía, sea esta expresa, troncal o colectora.

Lo mismo expresado anteriormente, se muestra en la tabla siguiente:

**Tabla 9. Muestra atributos explicativos seleccionados (Fuente: Elaboración Propia)**

Atributo Explicativo	Dato a recolectar	Naturaleza del Atributo
<b>Estructura de Pavimento</b>	<ul style="list-style-type: none"> <li>• Espesor de carpeta de rodado</li> <li>• Modulo resiliente de la subrasante</li> </ul>	Estático
<b>Historial de Condición Previo</b>	<ul style="list-style-type: none"> <li>• ICPU del ciclo previo a predecir (“t-1”)</li> </ul>	Dinámico
<b>Historial de Tránsito</b>	<ul style="list-style-type: none"> <li>• TMDA del ciclo previo a predecir</li> <li>• TMDA del ciclo a estimar</li> </ul>	Dinámico
<b>Clasificación Jerárquica</b>	<ul style="list-style-type: none"> <li>• Clasificación funcional proveniente de planes reguladores</li> </ul>	Estático

Con respecto a las solicitudes climáticas, estas no ingresarán como atributos explicativos al proceso de modelación, no por no tener relevancia, sino que, al estar situado el análisis en la Región Metropolitana de Santiago, se asume que todos los pavimentos se ven afectados al clima Mediterráneo (Osorio, 2015), por ende, no representan una variante dentro del contexto de modelación.

Ahora bien, esto no quiere decir que no se tomen en cuenta a la hora de seleccionar el escenario definitivo de modelación, pues la infraestructura vial se diseña de forma tal de poder soportar solicitudes climáticas tales como la precipitación. En ese sentido, las distintas vías que conforman la red vial urbana poseen algún tipo de sistema de evacuación de aguas lluvias, sean estos cunetas o sistemas colectores, lo que se identifica por la presencia de sumideros a lo largo de una determinada vía.

Dicho lo anterior, el tema climático queda incorporado en el análisis cuando se establece el escenario específico final de modelación, por mencionar un ejemplo de criterio discriminante, modelar solamente vías urbanas con sistema de evacuación de aguas lluvias en buen estado.

### **5.3 Confección de la base de datos.**

Teniendo claro los algoritmos seleccionados y también definidas las características a cuantificar de cada uno de los atributos explicativos, podemos comenzar con la confección de la base de datos experimental. Sin embargo, antes que todo, se explicitará el escenario a modelar.

#### **5.3.1 Escenario de Modelación.**

A lo largo de este escrito ya se han dado luces sobre el tipo de modelación que se intenta llevar a cabo. En ese sentido, se ha mencionado el primer gran diferenciador, que compete a modelar pavimentos urbanos. Como segundo, la aplicación de la metodología se da en el contexto de pavimentos urbanos de carpeta de rodadura asfáltica.

Otro punto discriminante es considerar solamente pavimentos perteneciente a la red vial primaria o estructurante, es decir, pavimentos urbanos de alta jerarquía, los que dentro de su clasificación funcional consideran vías del tipo “Expresas” y “Troncales” (MC – V3). Un aspecto importante dentro de este punto es la consideración también de vías del tipo “Colectoras”, esto con el justificativo de que, si bien fueron diseñadas como “Colectoras” (tipo de vía perteneciente a la red vial secundaria), el tránsito que hoy por hoy reciben se condice con una solicitud propia de vías de alta jerarquía.

En cuanto al tipo de tránsito, se modelan vías que posean tránsito mixto distribuido en vehículos livianos y pesados, siendo estos últimos correspondientes a buses del transporte público, servicios de aseo y carga de tonelajes medios, es decir, tránsito urbano casual. Lo anterior excluye del análisis vías exclusivas de corredores de Transantiago y avenidas diseñadas para tránsito pesado de características interurbanas.

Por último, se consideran dentro del análisis solamente aquellas vías que poseen su sistemas de aguas lluvias en buen estado, es decir, las que visualmente se logra observar con sus sumideros y cunetas destapados y a la altura correspondiente.

A modo de síntesis, se considera modelar vías con las condiciones de borde siguientes:

- Pavimentos urbanos de carpeta de rodadura asfáltica.
- Pavimentos pertenecientes a la red vial primaria con clasificación funcional de “Expresas”, “Troncales” y “Colectoras”.
- Pavimentos con tránsitos mixtos, liviano y pesado no incluyendo en el análisis vías exclusivas de Transantiago.
- Pavimentos con sistemas de evacuación de aguas lluvia en buen estado.

#### **5.3.2 Construcción de mini red de pavimentos urbanos.**

Esclarecido el escenario de modelación, se procede a la configuración de la mini red de pavimentos urbanos de la cual se obtendrán los datos para la modelación.

La Región Metropolitana de Santiago está subdividida en 32 municipios o comunas, siendo cada uno de ellos una agencia vial diferente, es decir, preservando los pavimentos exclusivos de su territorio y en la medida de sus posibilidades (Venegas, 2022; Diario Oficial de la República de Chile, 1992; Diario Oficial de la República de Chile, 2005; Diario Oficial de la República de Chile, 2006).

Por lo demás, se sabe que, al año 2020, la Región Metropolitana contaba ya con una red vial pavimentada de al menos 1500 [km] de extensión (MOP, 2020), lo que sin duda la sitúa como un excelente espacio para realizar análisis del desempeño de los pavimentos que constituyen dicha red.

Teniendo ese gran espectro para adquirir muestras de pavimento, se opta por recolectar información de los siguientes Municipios:

- Ilustre Municipalidad de Estación Central
- Ilustre Municipalidad de Macul
- Ilustre Municipalidad de Maipú
- Ilustre Municipalidad de Ñuñoa



**Figura 29. Muestra postales características de los cuatro municipios de los cuales se capturan datos (Fuente: Elaboración Propia).**


La decisión de auscultar en estos sectores de la capital de Santiago obedece al conocimiento zonal del desarrollador del trabajo, quien por paso frecuente poseía noción de vías que cumplían con las condiciones planteadas en el escenario de modelación y que, además, poseían un nivel de deterioro heterogéneo, lo que sin duda permitiría encontrar una diversificación de puntos en la escala de la variable dependiente en análisis, es decir, múltiples valores diferentes de ICPU.

De esta forma, se seleccionaron 30 vías de las que se lograron obtener 56 unidades muestrales (UM) para el proceso de modelación. En la tabla siguiente se disgrega la cantidad de vías por comuna y la cantidad de unidades muestrales obtenidas.


**Tabla 10. Muestra la cantidad de vías y número de unidades muestrales obtenidas (Fuente: Elaboración Propia)**

Comuna	Nº de Vías Analizadas	Nº de UM obtenidas
Estación Central	4	8
Macul	10	15
Maipú	11	19
Ñuñoa	6	14

A continuación, se presentan también figuras gráficas que muestran la distribución porcentual tanto de las vías analizadas como de las unidades muestrales obtenidas.



**Figura 30. Muestra la distribución porcentual de las vías analizadas (Fuente: Elaboración Propia)**



**Figura 31. Muestra la distribución porcentual de la cantidad de unidades muestrales obtenidas (Fuente: Elaboración Propia)**

Cabe destacar que se le denomina “Unidad Muestral” (UM), a la porción de pavimento de una respectiva vía que se selecciona para concurrir a realizar un proceso de auscultación manual en terreno, siendo la auscultación manual el procedimiento mediante el cual se realiza una inspección visual a la carpeta de rodadura midiendo y cuantificando los deterioros superficiales que esta posea con miras a obtener la métrica ICPU, o, en el caso de esta investigación, la obtención de la variable dependiente a modelar.

El detalle geográfico y unidades muestrales vistas se presentan en los anexos de este documento.

### 5.3.3 Auscultación en terreno y obtención del ICPU.

Seleccionadas las Unidades Muestrales, se concurrió a terreno para realizar el proceso de auscultación manual, proceso que se llevo a cabo con la incommensurable y solidaria colaboración del Profesional Técnico del Proyecto FONDECYT 11201150 Aníbal Godoy Mora.

La medición consistía en realizar un barrido en la respectiva unidad muestral, la cual correspondía a un área de 50 [m] de extensión por el largo de pista, la cual se subdividía en 5 porciones de área con extensión de 10 [m] por el largo de pista.

En cada una de las porciones de área debía registrarse información de los siguientes tipos de deterioros:

1. Piel de Cocodrilo o grieta de fatiga.



**Figura 32. Muestra grieta tipo piel de cocodrilo. Av. Marta Ossa Ruiz, Maipú (Fuente: Elaboración Propia)**

2. Grietas transversales o de reflexión



**Figura 33. Muestra deterioro tipo grieta transversal. Av. El Pinar, San Joaquín (Fuente: Elaboración Propia).**



**Figura 34. Muestra grietas transversales del tipo reflexión. Av. Las Parcelas, Estación Central  
(Fuente: Elaboración Propia)**

3. Baches



**Figura 35. Muestra deterioro tipo bache. Av. Marta Ossa Ruiz, Maipú (Fuente: Elaboración Propia)**

#### 4. Parches deteriorados



**Figura 36: Muestra deterioro tipo Parche Deteriorado. Av. Llancahue, Maipú (Fuente: Elaboración Propia)**

#### 5. Ahuellamiento



**Figura 37. Muestra deterioro de agrietamiento tipo Piel de Cocodrilo con ahuellamiento. Av. El Rosal, Maipú (Fuente: Elaboración Propia)**

La metodología para medir y cuantificar la extensión y zona de afectación que generaba cada uno de estos deterioros son las señaladas por Osorio, 2014. Las que a su vez se basan en los manuales de auscultación de la FHWA y el instructivo MOP para auscultación (FHWA, 2003; MOP, 2010).

Dicho lo anterior, se concurrió a terreno durante los veranos de 2022 y 2023 registrando los deterioros superficiales en la siguiente cartilla de auscultación:

Pavimento de Asfalto - Evaluación de Deterioros																																
Calle/Avenida:		Las palmar																														
Dirección:		paralelo a la capilla																														
Mante:																																
Comuna:		H-UM :																														
Sección de trazo:		curva norte										Pista asf.										pista ancho 2.5										
Nomenclatura:		MA-ALP-UM-3										Calzada										1										
Día de evaluación:		Evaluador																														
Tramo Ancho	Arietamiento Fatiga						Arietamiento Transversal						Grietas por Reflexión						Becker						Perfor Deteriorador						Alojamiento	
	Baja		Media		Alta		Baja		Media		Alta		Baja		Media		Alta		Baja		Media		Alta		Baja		Media		Alta			mm
	Ancho	Largo	Ancho	Largo	Ancho	Largo	Ancho	Largo	Ancho	Largo	Ancho	Largo	Ancho	Largo	Ancho	Largo	Ancho	Largo	RM	Rm	RM	Rm	RM	Rm	Ancho	Largo	Ancho	Largo	Ancho	Largo		
0 [m] - 10 [m]	0.2	0.7	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5
10 [m] - 20 [m]	0.2	0.7	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5
20 [m] - 30 [m]	0.2	0.7	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5
30 [m] - 40 [m]	0.2	0.7	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5
40 [m] - 50 [m]	0.2	0.7	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5	0.2	0.5
Observaciones:																																

Figura 38. Muestra planilla de auscultación de deterioros de pavimentos asfálticos utilizada durante las mediciones en terreno (Fuente: Elaboración Propia)

El cálculo u estimación del ICPU se realizó mediante la ecuación matemática planteada por Osorio, 2014, la cual se expuso en la Tabla 2 de este documento, obteniendo la distribución de datos que se expone en la tabla siguiente para las mediciones de terreno realizadas el verano del año 2022 y 2023:

Tabla 11. Muestra distribución de UM en cada rango de ICPU obtenidas durante el verano de 2021 (Fuente: Elaboración Propia)

Rango ICPU	Cantidad de UM en el rango años 2022	Cantidad de UM en el rango años 2023
[10 ; 9]	20	15
[9 ; 8]	11	6
[8 ; 7]	6	10
[7 ; 6]	5	7
[6 ; 5]	4	5
[5 ; 4]	1	3
[4 ; 3]	4	0
[3 ; 2]	3	5
[2 ; 1]	2	5

De la Tabla 11, se observan la distribución de ICPU para dos años o ciclos diferentes. Esto guarda relación con que los datos obtenidos para el año 2023 configuran la variable dependiente, en tanto que los años obtenidos durante el año 2022 corresponden a la condición del ciclo previo, que se utiliza como atributo explicativo.

### 5.3.4 Estimación del resto de Atributos Explicativos.

Anteriormente se mencionó que los atributos seleccionados para la modelación eran el espesor de la carpeta de rodadura del pavimento, el módulo resiliente de la subrasante, la sollicitación de tránsito estimada como TMDA (Tránsito Medio Diario Anual), la clasificación funcional y el estado de condición previo al ciclo a predecir.

De los anteriores atributos mencionados, solo la clasificación funcional y el estado de condición previo al ciclo a predecir, es decir, el ICPU antecesor del ciclo de predicción, corresponden a datos ciertos y fidedignos. La clasificación funcional se obtiene de los planes reguladores de los municipios en donde

se realizó la auscultación y el ICPU, como se comentó anteriormente, corresponde a una estimación certera de terreno.

#### 5.3.4.1 Atributos estáticos.

Para el caso de los atributos estáticos, como lo son el espesor del pavimento y el módulo resiliente de la subrasante, se tuvo que realizar una estimación en base a supuestos lógicos debido a que no se contó ni con recursos ni con autorización para extraer pruebas testigo de las distintas vías inspeccionadas.

Conforme a lo anterior, para ayudar al supuesto lógico de estimación, se requiere a lo explicitado en el “Manual de Obras Viales, Pavimentación y Aguas Lluvias” del SERVIU Metropolitano (SERVIU, 2018), el cual contiene, en su capítulo 1, cartillas de diseño que muestran distintos espesores de pavimento de acuerdo con las clasificaciones funcionales de las vías.

**Tabla 12. Muestra espesores de carpeta asfáltica dados por el Manual de Obras Viales, Pavimentación y Aguas Lluvias.**

Clasificación Funcional	Espesor asignado según cartilla [mm]
Colectora	120 o 140
Troncal	160
Expresa	180

Aún teniendo esta información, es una certeza de que sin pruebas testigo se desconocen los espesores reales de las vías, aunque algunas se pudieron estimar debido a presencia de baches severos que permitían observar hasta la base del pavimento, en esos casos se logró obtener de primera fuente el espesor, aunque no fueron más de 4 vías.

Dicho lo anterior, en forma arbitraria se crearon rangos de espesores generando una variación aleatoria de los datos por cartillas. De esta forma, los rangos de espesores quedan de la forma siguiente:

**Tabla 13. Muestra rango de espesores utilizados para las vías según clasificación funcional (Fuente: Elaboración Propia)**

Clasificación Funcional	Rango de espesor [mm]
Colectora	[90 ; 160]
Troncal	[160 ; 180]
Expresa	[180 ; 200]

Para el caso del módulo resiliente de la subrasante, también se genera una variación aleatoria en rangos de acuerdo con la clasificación funcional de las vías. Dichos rangos se muestran en la tabla siguiente:

**Tabla 14. Muestra rangos de módulos resilientes utilizados para las vías según su clasificación funcional (Fuente: Elaboración Propia)**

Clasificación Funcional	Rango de Módulo Resiliente [MPa]
Colectora	[30 ; 60]
Troncal	[60 ; 120]
Expresa	[120 ; 180]

### 5.3.4.2 Atributos Dinámicos.

El caso de los atributos dinámicos lo configura el tránsito, el cual busca representarse mediante un dato de tránsito medio diario anual (TMDA).

Respecto a este tipo de dato, se requiere estimar un dato de tránsito para el ciclo previo a predecir y uno que represente el tránsito del mismo ciclo de predicción. Para lograr lo anterior, se estudió la variación anual en la matrícula de vehículos motorizados examinando la data del Instituto Nacional de Estadísticas de Chile (INE) estableciendo un crecimiento anual promedio de 4% para la matrícula de vehículos de la Región Metropolitana.

Por lo demás, se definen rangos de TMDA haciendo un símil con lo realizado para los espesores y módulos resilientes, es decir, rangos específicos según clasificación funcional. Dichos valores se muestran en la tabla siguiente.

**Tabla 15. Muestra rangos de Tránsito Medio Diario Anual utilizados para las vías según su clasificación funcional (Fuente: Elaboración Propia)**

Clasificación Funcional	Rango de TMDA [veh/día]
Colectora	[200 ; 2000]
Troncal	[2000 ; 9000]
Expresa	[9000 ; 14000]

Dichos rangos de TMDA, si bien son arbitrarios, obedecen a un estudio de tránsito solicitado a la empresa GESINFRA, a la cual se le solicitó el estudio para caracterizar el tránsito de algunas de las vías seleccionadas para el estudio, reporte que fue entregado mediante el documento GP-032206-052-01 (Gespap, 2022).

### 5.3.5 Vista a la base de datos.

Habiendo estimado cada uno de los atributos explicativos seleccionados para predecir la variable dependiente, resta ordenarlos en una planilla, la cual sique la siguiente estructura:

**Tabla 16. Muestra estructura de la base de datos en planilla (Fuente: Elaboración Propia)**

ID UM	Clasificación Funcional	Espesor de Carpeta [mm]	Módulo Resiliente [MPa]	$TMDA_{t-1}$	$TMDA_t$	$ICPU_{t-1}$	$ICPU_t$

### 5.3.6 Confección de Curvas Teóricas de Desempeño.

Este apartado guarda relación con poseer un recurso que permita comparar y evaluar el rendimiento de los modelos de desempeño que emanen de las predicciones de cada uno de los algoritmos que se configuren.

En ese sentido, como se ha mencionado a lo largo de este documento, no existe en Chile un banco de datos en el cual se haya almacenado data de la progresión del deterioro de pavimentos. Por tal motivo, no existen curvas que ilustren el deterioro de los pavimentos urbanos en el tiempo a base de datos reales.

Con esta problemática sobre la mesa, se recurre a la “Metodología de Ventanas” planteada por Videla, 1992, la cual consiste en definir sectores de caminos homogéneos en cuanto a sus variables más representativas (estructura, tránsito, geometría y clima). Cada uno de estos tramos se considera una

ventana en la curva de comportamiento, que, junto con otras, pueden asimilar el comportamiento de un pavimento único. Entonces, si los tramos seleccionados poseen distintas edades, se puede construir la curva de desempeño del pavimento (Videla, et al., 1992; Solminihac, et al. 2002).

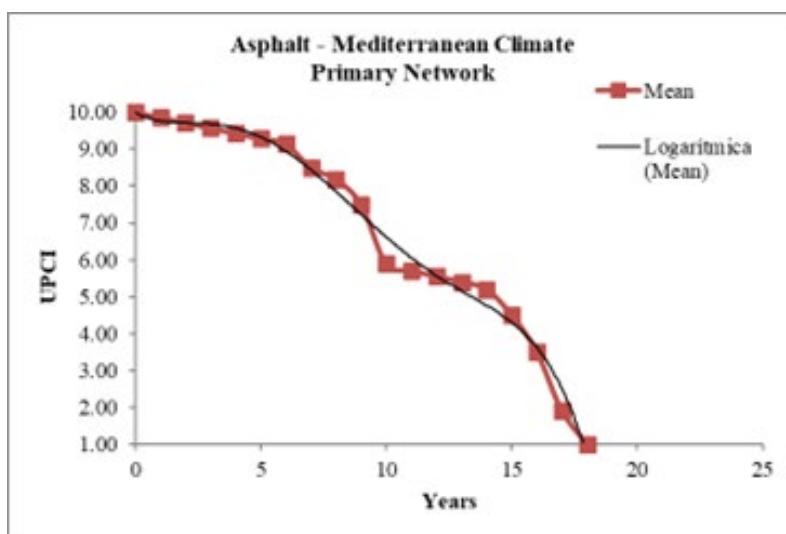
Dicho lo anterior, deben definirse criterios que permitan conformar una familia de pavimentos que permita configurar la curva de desempeño teórica para esta vía o pavimento simulado.

En cuanto a los criterios, ya varios se mencionan dentro de lo que es el escenario de modelación. Sin embargo, para no dejar lugar a dudas, aquí se enuncian nuevamente

- Vías pertenecientes a la red vial primaria o estructurante
- Vías de carpeta de rodadura asfáltica
- Vías con ancho de pista entre 3.3 y 3.6 [m]
- Vías con sistema de evacuación de aguas lluvias en buen estado
- Vías pertenecientes a una misma comuna

El último punto tiene que ver con que, debido a que cada municipio tiene calendarios de mantenimientos y formas de preservar los pavimentos distintas, es mejor separar los escenarios para prevenir posibles fluctuaciones debido a la posible disparidad en intervenciones. De esta forma, y una vez de haber evaluado los criterios, se opta por generar las curvas teóricas para las comunas de Maipú y Macul.

Una vez seleccionadas las vías para conformar las curvas teóricas de desempeño, se debe estimar la edad que debiese tener cada una de ellas. Dicho dato no fue posible obtener, por lo que, para realizar una estimación lógica de la edad, se recurrió al modelo Markoviano planteado por Osorio, 2015. Al cual se le realizó un ajuste polinómico de grado 5 para tener una expresión matemática que permitiera estimar el ICPU en función del tiempo.




**Figura 39. Modelo de desempeño para pavimentos asfálticos de alta jerarquía en clima mediterráneo. (Fuente: Osorio, 2015).**

$$ICPU = 10 - 8 * 10^{-5} * t^5 + 0.0032 * t^4 - 0.0438 * t^3 + 0.1996 * t^2 - 0.3923 * t \quad (5)$$

Con los recursos recién mencionados se logra estimar la edad referente a cada una de las unidades muestrales seleccionadas para confeccionar las curvas teóricas de desempeño, unidades muestrales que corresponden solo a las comunas de Maipú y Macul. Esto con el simple procedimiento de iterar la edad del pavimento conociendo el valor de ICPU real.

A continuación, se ilustra como se distribuyen cada una de las unidades muestrales en el tiempo.



**Figura 40. Muestra las curvas teóricas de terreno generadas representando familias de pavimentos para Macul y Maipú (Fuente: Elaboración Propia)**

Con esto concluye la etapa de confección de la base de datos, la cual se estructura con miras al entrenamiento de los algoritmos y también como elemento de comparación y contraste para evaluar el desempeño de las modelos de desempeño que se confeccionen.

#### 5.4 Configuración de Algoritmos.

Con la base de datos lista y procesada, prosigue configurar cada uno de los algoritmos a utilizar para así poder entrenar cada uno de ellos, evaluar su capacidad predictiva y utilizar cada uno de ellos para modelar el desempeño de los pavimentos prediciendo valores de ICPU.

A continuación, se exponen tablas en las cuales se dan a conocer cada uno de los hiperparámetros utilizados para la configuración de los algoritmos

**Tabla 17. Muestra hiperparámetros utilizados para la configuración de los algoritmos RFR y GBR (Fuente: Elaboración Propia)**

Hiperparámetro	Algoritmo Random Forest	Algoritmo GBR
N estimators	100	100
Min Samples Leaf	8	8

**Tabla 18. Muestra hiperparámetros utilizados para la configuración del algoritmo SVR (Fuente: Elaboración Propia)**

Hiperparámetro	Algoritmo Support Vector Regressor
Kernel o Núcleo	Rbf
C	3.0
Epsilon	0.15

Para el caso del algoritmo Support Vector Regressor se calibra un núcleo de características “No lineales”, puesto que el desempeño del pavimento en el tiempo no muestra una tendencia lineal.

**Tabla 19. Muestra hiperparámetros utilizados para la configuración de los algoritmos ANN y RNN (Fuente: Elaboración Propia)**

Hiperparámetro	Algoritmo Artificial Neuronal Network	Algoritmo Recurrent Neuronal Network
Nº de capas	4	3
Nº de neuronas por capa	8, 7, 7, 1	8, 12, 1
Función de Activación	Tanh, ReLU	ReLU
Tasa de Aprendizaje	0.01	0.01
Tipo de capa oculta	Densa	LSTM
Batch Size / Épocas de Entrenamiento	128 / 200	128 / 500

Estos hiperparámetros se consiguen luego de realizar múltiples pruebas con los distintos algoritmos, siendo estos los que lograron proveer mayor estabilidad.

## 5.5 Entrenamiento, Validación y Testeo.

Este paso se lleva tal cual como se indicó en el capítulo 4 de este escrito. Por ende, la base de datos se subdivide en dos grupos, uno destinado al entrenamiento, que consideró el 80% de la data y el remanente, es decir, el 20% restante del conjunto, se utilizó para la validación y testeo.

### 5.5.1 Resultados Validación simple.

A continuación, se dan a conocer los resultados para las métricas de desempeño RMSE y MAE provenientes de la validación simple.

**Tabla 20. Muestra resultados de las métricas de desempeño provenientes del proceso de validación simple**

Métrica / Algoritmo	RFR	GBR	SVR	ANN	RNN
RMSE	0.154	0.119	0.102	0.370	0.362
MAE	0.139	0.086	0.085	0.302	0.29
Accuracy	69%	81%	86%	-	-

### 5.5.2 Resultados Validación Cruzada.

Realizada la validación simple, y evaluada la precisión aparente de los algoritmos, se realiza el proceso de validación cruzada para examinar la capacidad de generalización de los algoritmos. Los resultados se muestran en las tablas siguientes.

**Tabla 21. Muestra resultados de prueba de validación cruzada para el algoritmo RFR (Fuente: Elaboración Propia)**

Algoritmo Random Forest Regressor										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.15	0.065	0.171	0.107	0.114	0.088	0.055	0.153	0.055	0.038
MAE	0.113	0.042	0.153	0.093	0.091	0.064	0.043	0.12	0.047	0.029

**Tabla 22. Muestra resultados de importancia estadística para la validación cruzada del algoritmo RFR (Fuente: Elaboración Propia)**

Información RMSE		Información MAE	
Max RMSE	0.171	Max RMSE	0.153
Min RMSE	0.038	Min RMSE	0.029
Promedio	<b>0.100</b>	Promedio	<b>0.080</b>
Desviación Estándar	0.0470	Desviación Estándar	0.0409
Intervalo de Confianza 95%	[0.04 ; 0.17]	Intervalo de Confianza 95%	[0.03 ; 0.146]

**Tabla 23. Muestra resultados de prueba de validación cruzada para el algoritmo GBR (Fuente: Elaboración Propia)**

Algoritmo Gradient Boosting Regressor										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.081	0.044	0.114	0.072	0.076	0.072	0.07	0.074	0.086	0.025
MAE	0.041	0.035	0.097	0.057	0.068	0.047	0.048	0.052	0.05	0.02

**Tabla 24. Muestra resultados de importancia estadística para la validación cruzada del algoritmo GBR (Fuente: Elaboración Propia)**

Información RMSE		Información MAE	
Max RMSE	0.114	Max RMSE	0.097
Min RMSE	0.025	Min RMSE	0.02
Promedio	<b>0.071</b>	Promedio	<b>0.0515</b>
Desviación Estándar	0.0237	Desviación Estándar	0.0205
Intervalo de Confianza 95%	[0.029 ; 0.111]	Intervalo de Confianza 95%	[0.023 ; 0.090]

**Tabla 25. Muestra resultados de prueba de validación cruzada para el algoritmo SVR (Fuente: Elaboración Propia)**

Algoritmo Support Vector Regressor										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.134	0.105	0.136	0.096	0.103	0.117	0.092	0.135	0.083	0.088
MAE	0.12	0.095	0.124	0.086	0.089	0.098	0.082	0.108	0.067	0.069

Tabla 26. Muestra resultados de importancia estadística para la validación cruzada del algoritmo SVR (Fuente: Elaboración Propia)

Información RMSE		Información MAE	
Max RMSE	0.136	Max RMSE	0.124
Min RMSE	0.083	Min RMSE	0.067
Promedio	<b>0.11</b>	Promedio	<b>0.09</b>
Desviación Estándar	0.0203	Desviación Estándar	0.0194
Intervalo de Confianza 95%	[0.083 ; 0.135]	Intervalo de Confianza 95%	[0.067 ; 0.123]

Tabla 27. Muestra resultados de prueba de validación cruzada para el algoritmo ANN (Fuente: Elaboración Propia)

Algoritmo Artificial Neuronal Network										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.0907	0.1388	0.2239	0.0442	0.6601	0.1257	0.1858	0.1728	0.0935	0.3847
MAE	0.1575	0.1333	0.0220	0.1714	0.0729	0.1093	0.6982	0.7862	0.0914	0.3531

Tabla 28. Muestra resultados de importancia estadística para la validación cruzada del algoritmo ANN (Fuente: Elaboración Propia)

Información RMSE		Información MAE	
Max RMSE	0.6601	Max RMSE	0.7862
Min RMSE	0.0442	Min RMSE	0.0220
Promedio	<b>0.21</b>	Promedio	<b>0.26</b>
Desviación Estándar	0.1834	Desviación Estándar	0.2697
Intervalo de Confianza 95%	[0.054 ; 0.59]	Intervalo de Confianza 95%	[0.03 ; 0.76]

Tabla 29. Muestra resultados de prueba de validación cruzada para el algoritmo RNN (Fuente: Elaboración Propia)

Algoritmo Recurrent Neuronal Network										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.1177	0.1360	0.1667	0.0572	0.1826	0.0827	0.1656	0.1936	0.1492	0.0919
MAE	0.0872	0.1336	0.1454	0.0732	0.1660	0.0636	0.1305	0.1791	0.1300	0.0543

Tabla 30. Muestra resultados de importancia estadística para la validación cruzada del algoritmo RNN (Fuente: Elaboración Propia)

Información RMSE		Información MAE	
Max RMSE	0.1936	Max RMSE	0.1791
Min RMSE	0.0572	Min RMSE	0.0543
Promedio	<b>0.13</b>	Promedio	<b>0.12</b>
Desviación Estándar	0.0457	Desviación Estándar	0.0438
Intervalo de Confianza 95%	[0.063 ; 0.191]	Intervalo de Confianza 95%	[0.056 ; 0.176]

**Tabla 31. Muestra cuadro resumen con los resultados promedio de las métricas de desempeño**

(Fuente: Elaboración Propia)

Métrica / Algoritmo	RFR	GBR	SVR	ANN	RNN
Promedio RMSE	0.100	0.071	0.109	0.212	0.134
Promedio MAE	0.080	0.052	0.094	0.260	0.116

### 5.6 Selección definitiva de variables independientes o atributos explicativos.

Realizados los exámenes de las métricas tanto para validación simple como validación cruzada, se realiza el estudio de importancia de las variables. Para ello, de los análisis planteados en la metodología, se realiza la prueba de Información Mutua, por detectar en su análisis tanto relaciones lineales como no lineales. El resultado fue el siguiente:

**Tabla 32. Muestra resultados de prueba de Información Mutua (Fuente: Elaboración Propia)**

Variable Independiente	Resultado Prueba Información Mutua
Espesor de carpeta asfáltica	0.2
Módulo Resiliente	0.0
$TMDA_{t-1}$	0.07
$TMDA_t$	0.07
$ICPU_{t-1}$	1.46

El resultado muestra que la variable de mayor importancia es el ICPU representativo de la condición del ciclo previo al de predicción, seguido luego del espesor de carpeta asfáltica, luego las variables de tránsito y, por último, el módulo resiliente sin ningún tipo de relación. Resultados llamativos que se discutirán en el capítulo 7 “Análisis de Resultados”.


La clasificación funcional no entra en este análisis por ser un atributo categórico, es decir, no numérico.

Realizada esta prueba, se seleccionan como atributos finales todas las características a excepción del módulo resiliente. En cuanto a los resultados de las métricas de desempeño, estos no varían, pues el módulo resiliente no tiene ningún tipo de capacidad predictiva.

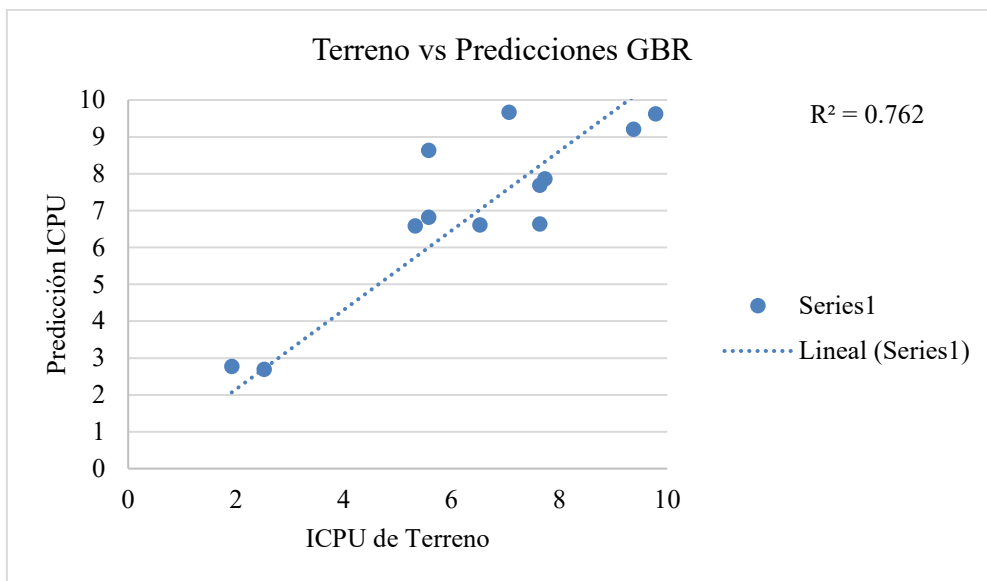
### 5.7 Predicción a Corto y Largo Plazo.

Configurados y calibrados los algoritmos con los atributos explicativos definitivos, se realizan las pruebas de predicción.


### 5.7.1 Resultados de predicción a corto plazo.




**Figura 41. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo RFR**  
(Fuente: Elaboración Propia)




**Figura 42. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo GBR**  
(Fuente: Elaboración Propia)



**Figura 43. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo SVR (Fuente: Elaboración Propia)**



**Figura 44. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo ANN (Fuente: Elaboración Propia)**



**Figura 45. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo RNN**  
**(Fuente: Elaboración Propia)**

### 5.7.2 Resultados de Predicción a Largo Plazo.

Realizadas las predicciones a corto plazo, se pone a prueba la capacidad predictiva de los diferentes algoritmos utilizándolos de forma recursiva para que, en base a sus propias predicciones, conformen las curvas de desempeño.


Para generar estas curvas, se entrega el siguiente vector de atributos a cada algoritmo:

**Tabla 33. Muestra vector de atributos dado a cada modelo para la predicción a largo plazo**

**(Fuente: Elaboración Propia)**

Espesor Asfalto	$ICPU_{t-1}$	$TMDA_{t-1}$	$TMDA_t$	CF
160 [mm]	10	5000	5200	Troncal

El resultado obtenido se muestra en la figura siguiente, el cual se contrasta inmediatamente con las curvas teóricas de desempeño planteadas en el tercer punto de este capítulo.



**Figura 46. Muestra modelos de desempeño obtenidos contrastados con las curvas de desempeño teóricas planteadas en 5.3.6 (Fuente: Elaboración Propia).**

### 5.8 Comentario.

A modo de comentario sobre los resultados obtenidos, se puede decir que, para la predicción a corto plazo, el algoritmo con mejor desempeño es el GBR, seguido de cerca por todos los otros. De todas formas, de las gráficas comparativas de las predicciones versus los datos reales de terreno, se observa que la variación existente es alta y que ninguno de los algoritmos es completamente certero a la hora de predecir teniendo un grado de error importante a la hora de tener que estimar valores de ICPU para rangos medios. De lo anterior se desprende que, a pesar del ajuste de hiperparámetros, existe algo de subajuste debido a la poca cantidad de datos que posee el conjunto de entrenamiento.

Con respecto a la predicción a largo plazo, se aprecian resultados dispares. Los únicos algoritmos capaces de generar una curva “suave” y lógica son los de inspiración biológica, es decir ANN y RNN, siendo el último mencionado el que consigue un resultado sumamente parecido a las curvas teóricas de desempeño. Del resto de algoritmos, GBR y RFR poseen predicciones cercanas a las curvas teóricas de desempeño durante los primeros 4 años de horizonte de predicción. A posterior, su capacidad predictiva decae notablemente.

En el caso del algoritmo SVR, este en ningún momento se acerca a las curvas teóricas de desempeño, mostrando en todo momento una progresión de deterioro acelerada que alcanza el mínimo valor de ICPU al año 5.

Esto como comentarios preliminares, el análisis exhaustivo se realiza en el capítulo 7 de este documento.

## 6 Aplicación de la Metodología a base de datos sintética con validación a mini red de pavimentos urbanos.

Realizada la aplicación de la metodología con la base de datos confeccionada, es claro que el resultado es perfectible. La predicción a corto plazo, si bien muestra un nivel de error relativamente bajo, sin duda alguna puede mejorar. Por lo demás, de las predicciones a largo plazo obtenidas, solo las obtenidas para

el algoritmo RNN muestran un comportamiento en concordancia con las curvas teóricas de terreno planteadas.

La principal tesis que se tiene respecto al tema, y condicionante importante de los resultados obtenidos, guarda directa relación con el tamaño de la base de datos conseguida, pues, de las 56 unidades muestrales conseguidas, solo 45 se utilizan en el entrenamiento. Si consideramos, además, que de la selección final de atributos explicativos se termina por utilizar 5 de ellos (4 atributos numéricos y 1 categórico representativo de la Clasificación Funcional), se está bordeando la condición mínima de datos de entrenamiento expuesta por Chicco, 2017, es decir, al menos 10 veces la cantidad de atributos explicativos.

Por lo demás, algo que perjudica el aprendizaje de los algoritmos de Inteligencia Artificial es poseer una base de datos desbalanceada y, si observamos la cantidad de datos por rango de ICPU expuestos en la tabla 11 del capítulo 5, resulta más que evidente de que el conjunto de datos se encuentra concentrado en valores de ICPU altos, por tal motivo, es de esperar una baja capacidad predictiva para rangos bajos de ICPU si cada uno de los algoritmos posee pocos ejemplos para aprender el comportamiento que tiene el índice en dichos rangos.

Ante tal situación, y en un afán de evidenciar cuanto mejora la capacidad predictiva de los distintos algoritmos con una base de datos de mayor cuantía, se opta por confeccionar una completamente sintética dejando la confeccionada con datos reales en el capítulo 5 de este documento para la evaluación de las métricas de desempeño y, consecuentemente, para la validación de los modelos configurados.

Dicho lo anterior, se procede nuevamente con la aplicación de la metodología. En ese sentido, lo correspondiente a los pasos 1 y 2 del proceso metodológico conservan lo emanado del capítulo 5 de este documento, por lo que no se entrará en mayor detalle por ser absolutamente reiterativo. Por ende, se avanza directamente al paso número 3 relativo a la confección y procesamiento de la base de datos.

## **6.1 Confección y procesamiento de la base de datos sintética.**

Con respecto a la confección de la base de datos, esta no cambia la filosofía de lo realizado en la base de datos reales, es decir, el escenario de modelación se mantiene. Con esto se quiere decir que, se conserva la idea original de modelar pavimentos urbanos de carpeta de rodadura asfáltica, pertenecientes a la red vial primaria, con una sollicitación de tránsito mixto y que conserven su sistema de aguas lluvias en buen estado.

A fin de cuentas, gran parte de lo realizado en la confección de la base de datos expuesta en el capítulo 5 de este escrito, se repite en la materialización de este nuevo conjunto de datos. Esto porque, de lo expuesto en el capítulo anterior, lo referente a los atributos explicativos de espesor de carpeta de rodado, módulo resiliente de subrasante y tránsito, ya resultaban de estimaciones que, si bien provienen de supuestos lógicos, no son más que valores virtuales o sintéticos, pues no se contaba con esa información certera de terreno.

Entonces, el gran atributo explicativo a estimar son los datos de ICPU correspondientes a los ciclos " $t - 1$ " y " $t$ ", siendo este último el correspondiente a la variable dependiente a predecir.

### **6.1.1 Estimación sintética del ICPU.**

Para la estimación sintética del ICPU se realiza un procedimiento similar a lo expuesto en el numeral 5.3.6 de este documento para la estimación de la edad de los pavimentos en función de su ICPU. Solo que para este caso el procedimiento se aplica a la inversa. Es decir, esta vez se plantean distintos instantes temporales o edades virtuales, para así conseguir un valor de ICPU virtual pero coherente.

Dicho lo anterior, se estructura un vector de edades con valores entre 0 y 20 [años] con paso de tiempo elegido en forma arbitraria de 0.02 [años].

Con este vector y por medio de la ecuación (5), expuesta también en el numeral 5.3.6 de este documento, se estiman 1000 valores distintos de ICPU correspondientes al atributo explicativo  $ICPU_{t-1}$ . En tanto que, para la estimación de los datos asignados a la variable dependiente, sencillamente se le suma 1 [año] a cada valor del vector de edades con miras a obtener el  $ICPU_t$ . De esta forma, y nuevamente

usando la ecuación (5) expuesta en el numeral 5.3.6 de este documento, se estiman los valores  $ICPU_t$  o variable dependiente a predecir.

A continuación, en la tabla siguiente, se muestra la cantidad de unidades muestrales virtuales presentes por rango de ICPU.

**Tabla 34. Muestra distribución de UM en cada rango de ICPU obtenidas para la base de datos sintética (Fuente: Elaboración Propia)**

Rango ICPU	Cantidad de UM virtuales ( $ICPU_{t-1}$ )	Cantidad de UM virtuales ( $ICPU_t$ )
[10 ; 9]	94	11
[9 ; 8]	78	99
[8 ; 7]	79	86
[7 ; 6]	86	90
[6 ; 5]	101	102
[5 ; 4]	122	121
[4 ; 3]	156	157
[3 ; 2]	223	222
[2 ; 1]	61	112

### 6.1.2 Estimación de la Clasificación Funcional.

Para lo que es la clasificación funcional, se conservan las tres clases utilizadas en la confección de la base de datos utilizada en el capítulo 5 de este documento. Solo que, al ser estas nuevas unidades muestrales virtuales, o sintéticas, la clasificación funcional se otorga mediante una función aleatoria en Excel.

### 6.1.3 Estimación del resto de atributos explicativos.

Asignada una respectiva Clasificación Funcional a cada una de las unidades muestrales sintéticas, el resto de los atributos explicativos se estima de forma aleatoria utilizando los mismos criterios planteados en el numeral 5.3.4 de este documento

## 6.2 Selección definitiva de atributos explicativos.

Antes de realizar los procesos siguientes de la metodología, al tener el antecedente de los resultados obtenidos con la base de datos reales, se realiza el estudio para medir la importancia de las características seleccionadas como atributos explicativos mediante las pruebas ANOVA (f-value) e Información Mutua (MI).

El estudio realizado a la base de datos utilizada en el capítulo 5 de este documento ya había restado importancia a la variable tránsito y quitado absoluta utilidad a la variable “Módulo Resiliente de la subrasante”. Sin embargo, la base de datos no poseía un número considerable de muestras.

Ante tal situación, se realizan nuevamente las pruebas con miras a saber si es que la tendencia se mantiene.

En primera instancia, se muestran los resultados obtenidos para la prueba ANOVA.

**Tabla 35. Muestra resultados para la prueba ANOVA realizada para medir la relación de las variables independientes con la dependiente (Fuente: Elaboración Propia)**

<b>Variable Independiente</b>	<b>Resultado Prueba ANOVA (f-value)</b>
<b>Espesor de carpeta asfáltica</b>	3.89
<b>Módulo Resiliente</b>	0.96
<i>TMDA<sub>t-1</sub></i>	0.98
<i>TMDA<sub>t</sub></i>	0.98
<i>ICPU<sub>t-1</sub></i>	375

Ahora, se exponen los resultados de la prueba de Información Mutua.

**Tabla 36. Muestra resultados para la prueba de Información Mutua realizada para medir la relación de las variables independientes con la dependiente (Fuente: Elaboración Propia)**

<b>Variable Independiente</b>	<b>Resultado Prueba Información Mutua</b>
<b>Espesor de carpeta asfáltica</b>	0.20
<b>Módulo Resiliente</b>	0.00
<i>TMDA<sub>t-1</sub></i>	0.00
<i>TMDA<sub>t</sub></i>	0.00
<i>ICPU<sub>t-1</sub></i>	4.64

Cabe recordar que la prueba ANOVA examina solo relaciones lineales entre las variables independientes con las dependientes. En tanto que la prueba de información mutua es capaz de capturar no solo las lineales, sino que también las no lineales.

Habiendo realizado ambas pruebas, se nota que el resultado resulta similar en ambas. La variable independiente o atributo explicativo de mayor relevancia continúa siendo la condición del pavimento en el instante o año previo a la predicción, seguido en importancia por el espesor de carpeta asfáltica, luego por los atributos correspondientes a la variable tránsito y, en último lugar, el módulo resiliente de la subrasante.

Ahora bien, cabe destacar que tanto para la prueba ANOVA como para la de Información Mutua, la variable de condición previa posee una importancia abrumadoramente superior, lo cual la sitúa como variable principal del estudio, mientras que el resto podría incluso obviarse.

Como paso final, se seleccionan los 4 atributos explicativos de mayor importancia, los cuales incorporan el espesor de carpeta asfáltica, las variables de tránsito y la condición previa al ciclo a predecir.

### **6.3 Configuración de los algoritmos.**

Con respecto a este apartado, se preservan cada uno de los hiperparámetros ya testeados en el apartado 5.4 de este documento y que ya fueron expuestos en las tablas 17, 18 y 19.

Configurados los algoritmos, se inicia la etapa de entrenamiento, validación y testeo.

#### 6.4 Entrenamiento, Validación y Testeo con base de datos sintética.

Con la base de datos estimada y procesada, y teniendo configurado también los 5 algoritmos planteados para los estudios, resta realizar el entrenamiento y las pruebas de validación y testeo. Para ello se prepara cada conjunto de datos quedando configurados de la manera siguiente:

**Tabla 37. Muestra información acerca de los conjuntos de datos utilizados para entrenamiento, validación y testeo (Fuente: Elaboración Propia)**

Conjunto de Datos	Cantidad	Naturaleza de los datos
Entrenamiento	800	Sintéticos
Validación	200	Sintéticos
Testeo	56	Reales

##### 6.4.1 Resultados Validación Simple.

A continuación, se exponen los resultados para las métricas RMSE, MAE y Accuracy (Accuracy solo para los algoritmos del tipo ML)

**Tabla 38. Muestra resultados de las métricas de desempeño provenientes del proceso de validación simple (Fuente: Elaboración Propia)**

Métrica / Algoritmo	RFR	GBR	SVR	ANN	RNN
RMSE	0.004	0.003	0.08	0.05	0.04
MAE	0.002	0.002	0.07	0.03	0.03
Accuracy	0.999	0.999	0.940	-	-

##### 6.4.2 Resultados Validación Cruzada.

Realizado el entrenamiento y las pruebas de validación simple, se exponen a continuación los resultados obtenidos para el proceso de validación cruzada.

###### 6.4.2.1 Resultados métricas de desempeño

**Tabla 39. Muestra resultados de prueba de validación cruzada para el algoritmo RFR (Fuente: Elaboración Propia)**

Métrica / N° Split	Algoritmo Random Forest Regressor									
	1	2	3	4	5	6	7	8	9	10
RMSE	0.003	0.002	0.004	0.002	0.003	0.003	0.003	0.002	0.002	0.002
MAE	0.002	0.001	0.002	0.001	0.002	0.002	0.002	0.001	0.001	0.001

Tabla 40. Muestra resultados de importancia estadística para la validación cruzada del algoritmo RFR (Fuente: Elaboración Propia)

Información RMSE		Información MAE	
Max RMSE	0.004	Max RMSE	0.002
Min RMSE	0.002	Min RMSE	0.001
Promedio	0.003	Promedio	0.002
Desviación Estándar	0.0007	Desviación Estándar	0.0005
Intervalo de Confianza 95%	[0.002 ; 0.0038]	Intervalo de Confianza 95%	[0.001 ; 0.002]

Tabla 41. Muestra resultados de prueba de validación cruzada para el algoritmo GBR (Fuente: Elaboración Propia)

Algoritmo Gradient Boosting Regressor										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.003	0.002	0.003	0.003	0.002	0.003	0.002	0.002	0.003	0.003
MAE	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002	0.002

Tabla 42. Muestra resultados de importancia estadística para la validación cruzada del algoritmo GBR (Fuente: Elaboración Propia)

Información RMSE		Información MAE	
Max RMSE	0.003	Max RMSE	0.002
Min RMSE	0.002	Min RMSE	0.002
Promedio	0.003	Promedio	0.002
Desviación Estándar	0.0005	Desviación Estándar	0.0000
Intervalo de Confianza 95%	[0.002 ; 0.003]	Intervalo de Confianza 95%	[0.002 ; 0.0022]

Tabla 43. Muestra resultados de prueba de validación cruzada para el algoritmo SVR (Fuente: Elaboración Propia)

Algoritmo Support Vector Regressor										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.094	0.083	0.1	0.092	0.083	0.09	0.092	0.087	0.084	0.097
MAE	0.075	0.068	0.085	0.073	0.064	0.073	0.073	0.067	0.064	0.078

Tabla 44 Muestra resultados de importancia estadística para la validación cruzada del algoritmo SVR (Fuente: Elaboración Propia)

Información RMSE		Información MAE	
Max RMSE	0.1	Max RMSE	0.085
Min RMSE	0.083	Min RMSE	0.064
Promedio	0.09	Promedio	0.07
Desviación Estándar	0.0059	Desviación Estándar	0.0065
Intervalo de Confianza 95%	[0.083 ; 0.099]	Intervalo de Confianza 95%	[0.064 ; 0.083]

**Tabla 45. Muestra resultados de prueba de validación cruzada para el algoritmo ANN (Fuente: Elaboración Propia)**

Algoritmo Artificial Neuronal Network										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.0680	0.0330	0.1570	0.0530	0.1000	0.0990	0.0530	0.0460	0.0778	0.1430
MAE	0.0694	0.1140	0.1225	0.0371	0.1245	0.0860	0.0440	0.0174	0.2740	0.1280

**Tabla 46. Muestra resultados de importancia estadística para la validación cruzada del algoritmo ANN (Fuente: Elaboración Propia)**

Información RMSE		Información MAE	
Max RMSE	0.1570	Max RMSE	0.2740
Min RMSE	0.0330	Min RMSE	0.0174
Promedio	0.08	Promedio	0.10
Desviación Estándar	0.0416	Desviación Estándar	0.0726
Intervalo de Confianza 95%	[0.006 ; 0.64]	Intervalo de Confianza 95%	[0.02 ; 0.86]

**Tabla 47. Muestra resultados de prueba de validación cruzada para el algoritmo RNN (Fuente: Elaboración Propia)**

Algoritmo Recurrent Neuronal Network										
Métrica / N° Split	1	2	3	4	5	6	7	8	9	10
RMSE	0.0530	0.0293	0.0364	0.0489	0.0283	0.0690	0.0304	0.0560	0.0577	0.1155
MAE	0.0673	0.0295	0.0255	0.0323	0.0352	0.0414	0.0591	0.0641	0.0510	0.1240

**Tabla 48. Muestra resultados de importancia estadística para la validación cruzada del algoritmo RNN (Fuente: Elaboración Propia)**


Información RMSE		Información MAE	
Max RMSE	0.1155	Max RMSE	0.1240
Min RMSE	0.0283	Min RMSE	0.0255
Promedio	0.05	Promedio	0.05
Desviación Estándar	0.0262	Desviación Estándar	0.0291
Intervalo de Confianza 95%	[0.024 ; 0.068]	Intervalo de Confianza 95%	[0.016 ; 0.057]

**Tabla 49. Muestra cuadro resumen con los resultados promedio de las métricas de desempeño (Fuente: Elaboración Propia)**


Métrica / Algoritmo	RFR	GBR	SVR	ANN	RNN
Promedio RMSE	0.003	0.003	0.090	0.083	0.052
Promedio MAE	0.002	0.002	0.072	0.102	0.053

#### 6.4.2.2 Resultados gráficos de predicción.


Examinado el desempeño luego del proceso de validación cruzada, se examinan los resultados de las predicciones con el conjunto de validación remanente de la base sintética (200 datos que no se utilizaron para el entrenamiento).




**Figura 47. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo RFR usando conjunto de validación sintético (Fuente: Elaboración Propia)**




**Figura 48. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo GBR usando conjunto de validación sintético (Fuente: Elaboración Propia)**



**Figura 49. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo SVR usando conjunto de validación sintético (Fuente: Elaboración Propia)**



**Figura 50. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo ANN usando conjunto de validación sintético (Fuente: Elaboración Propia)**



**Figura 51. Muestra gráfica comparativa de predicciones a corto plazo para el algoritmo RNN usando conjunto de validación sintético (Fuente: Elaboración Propia)**

### 6.4.3 Testeo con conjunto de datos reales.


Vistos los resultados de las métricas de desempeño, tanto numéricos como gráficos, resta la obtención de las métricas de desempeño, pero ahora viendo la real capacidad predictiva de los modelos a la hora de interpretar el valor de la variable dependiente con los datos proveniente de la base de datos con las medidas de terreno de ICPU.

**Tabla 50. Muestra cuadro resumen con los resultados promedio de las métricas de desempeño obtenidas del testeo con datos reales (Fuente: Elaboración Propia)**


Métrica / Algoritmo	RFR	GBR	SVR	ANN	RNN
Promedio RMSE	0.053	0.051	0.104	0.36	0.35
Promedio MAE	0.0355	0.0335	0.0825	0.376	0.38

## 6.5 Predicción a corto y largo plazo.


### 6.5.1 Resultados Predicción a Corto Plazo.




**Figura 52. Muestra resultado de predicción a corto plazo para el algoritmo RFR utilizando la base de datos reales (Fuente: Elaboración Propia)**




**Figura 53. Muestra resultado de predicción a corto plazo para el algoritmo GBR utilizando la base de datos reales (Fuente: Elaboración Propia)**



**Figura 54. Muestra resultado de predicción a corto plazo para el algoritmo SVR utilizando la base de datos reales (Fuente: Elaboración Propia)**



**Figura 55. Muestra resultado de predicción a corto plazo para el algoritmo ANN utilizando la base de datos reales (Fuente: Elaboración Propia)**



**Figura 56. Muestra resultado de predicción a corto plazo para el algoritmo RNN utilizando la base de datos reales (Fuente: Elaboración Propia)**

### 6.5.2 Resultados Predicción a Largo Plazo.


Para la predicción a largo plazo y consecuente obtención de los modelos de desempeño, se realiza lo mismo expuesto anteriormente en el numeral 5.7.2 de este documento, es decir, entregar un vector de atributos a cada algoritmo para que en función de sus propias predicciones desarrolle las respectivas curvas.

A continuación, se expone el vector de atributos entregado:

**Tabla 51. Muestra vector de atributos dado a cada modelo para la predicción a largo plazo (Fuente: Elaboración Propia)**

Espesor Asfalto	$ICPU_{t-1}$	$TMDA_{t-1}$	$TMDA_t$	CF
160 [mm]	10	5000	5200	Troncal

A continuación, se exponen los modelos de desempeño obtenidos como resultado de la predicción a largo plazo:



## 6.6 Comentario.

A modo de comentario, mencionar que, habiendo entrenado los algoritmos con una base sintética de 800 datos, a simple vista, se obtienen mejores resultados, sean estas predicciones a corto plazo y largo plazo.

De los resultados de predicción a corto plazo, solo con observar los resultados gráficos expuestos en las figuras 52, 53, 54, 55 y 56 se aprecia una estimación con un rango de variación mucho menor. Esto se todavía más visible si se contrastan con las figuras 41, 42, 43, 44 y 45, que fueron los resultados obtenidos cuando los algoritmos se calibraron solamente utilizando la bases de datos reales.

En cuanto a los resultados obtenidos por los modelos de desempeño, la primera diferencia apreciada es que todos los algoritmos son capaces de generar curvas suaves, sin grandes saltos ni pronunciaciones poco lógicas. Por lo demás, ya no es solo el algoritmo RNN el que muestra un comportamiento similar a las curvas teóricas de terreno, le siguen también los algoritmos RFR y GBR.

El algoritmo ANN, si bien muestra un desarrollo lógico del modelo de desempeño, continúa mostrando un deterioro muy acelerado de la condición del pavimento, lo que no se condice con el comportamiento de las curvas teóricas de terreno obtenidas para las comunas de Macul y Maipú.

Por último, el algoritmo SVR, más que seguir el comportamiento en el tiempo de un pavimento, parece haber modelado un comportamiento asintótico que no desciende del valor 3, lo cual no resulta coherente con lo esperado.

## 7 Análisis de Resultados.

### 7.1 Atributos explicativos seleccionados.

En cuanto al análisis de los atributos explicativos seleccionados para modelación, se referirá primeramente a lo netamente numérico, de lo cual se tiene lo siguiente:

**Tabla 52. Muestra resultados de las pruebas ANOVA e Información Mutua (Fuente: Elaboración Propia)**

Variable Independiente	Resultado Prueba ANOVA (f-value)	Prueba Información Mutua (MI)
Espesor de carpeta asfáltica	3.89	0.20
Módulo Resiliente	0.96	0.00
$TMDA_{t-1}$	0.98	0.00
$TMDA_t$	0.98	0.00
$ICPU_{t-1}$	375	4.64

De lo anterior se desprende que la variable de principal importancia es el valor de ICPU del ciclo inmediatamente anterior al ciclo a predecir. Este resultado tiene particular concordancia con los análisis ya realizados por Marcelino, et al., 2019 y Montecinos, 2022, quienes dieron cuenta que, al ser el deterioro de los pavimentos un proceso dinámico, no puede no considerarse el historial de condición previo que este pueda tener.

Por otra parte, el resto de los atributos explicativos, salvo el espesor de carpeta asfáltica, poseen relaciones particularmente bajas con la variable a predecir. Es más, para ambos estudios, el módulo resiliente no logró mostrar ni relación lineal ni no lineal con el valor de ICPU que se debía predecir.

En la misma tónica, se tiene un resultado muy bajo de relación, sea lineal o no lineal, de la variable tránsito. La prueba ANOVA logra captar algo de relación, sin embargo, la prueba de Información Mutua no expone relación alguna. Pese a lo anterior, y por ser considerada en la mayoría de las investigaciones revisadas (Mazari y Rodríguez 2016; Marcelino, et al., 2019; Hossain, et al., 2019; Choi y Do, 2019; Zhou, et al., 2021; Yang, et al., 2021; Haddad, et al., 2021; Montecinos, 2022), se opta por preservarla en el análisis.

Aun así, es importante mencionar que quizás no se está trabajando de la forma idónea, por lo que, para futuras investigaciones queda como tarea analizarla de otra forma, por ejemplo, como peso de eje, ejes equivalentes, disgregando por tipo y cantidad de vehículos, etc.

Lo mismo aplica para la variable independiente “Módulo Resiliente de Subrasante”, la cual podría partir por analizarse haciendo el esfuerzo de conseguir datos reales de terreno, o, en caso de no poder obtener dicha información, iterar con otros rangos de variación, pues puede ser también que el supuesto planteado para su estimación no sea lógico.


Por último, se debe mencionar que es importante analizar la relación de los atributos explicativos con la variable dependiente, puesto que considerar atributos erróneos incide en la confusión de los algoritmos y puede llegar a obtenerse un resultado final no esperado. Además, si bien este no es el caso, incluir atributos extras en el análisis, que no sean del todo representativos del problema en estudio, puede derivar en un gasto computacional extra que vaya en desmedro de una consecución eficaz de resultados.

## 7.2 Métricas de desempeño.

### 7.2.1 Métrica de desempeño RMSE.

La raíz del error cuadrático medio es un tipo de análisis que permite cuantificar el grado de error de un modelo predictivo en base a la diferencia cuadrada entre el valor estimado y un dato comparativo. Cuando se utiliza, tiene el objetivo de minimizarse, pues mientras más pequeño el RMSE, el modelo estima de mejor manera.

Teniendo en cuenta lo anterior, se compara gráficamente la métrica promedio obtenida para los procesos de entrenamiento y testeo ya sea de lo obtenido con la base de datos real expuesta en el capítulo 5, que se denominará “Análisis 1”, y lo obtenido luego de entrenar los algoritmos con la base sintética obtenida en el capítulo 6 y validado con el conjunto de datos reales, que será denominado análisis 2.




**Figura 57. Muestra comparativa de la métrica RMSE obtenida para entrenamiento (Fuente: Elaboración Propia)**

De esta gráfica se desprende que, para la fase de entrenamiento, el análisis 2 posee un nivel de error mucho menor, siendo especialmente bajo para los algoritmos RFR y GBR. Para el caso de los algoritmos SVR, ANN y RNN, si se compara el análisis 1 y 2, también se observa una tendencia de disminución del error. Sin embargo, esta no resulta tan drástica como si ocurre para los dos primeros algoritmos mencionados.

Hasta este punto, el análisis resulta lógico. Sin embargo, cuando se comparan las métricas obtenidas del análisis de las predicciones, el resultado resulta algo distinto, pues, si bien se observa el mismo comportamiento de disminución en el error con los algoritmos RFR, GBR y SVR, para el caso de los algoritmos de inspiración biológica, es decir ANN y RNN, ocurre precisamente lo contrario, siendo superiores los valores de RMSE obtenidos para el análisis 2, tal como se observa en la figura 58.

Esto puede deberse a la estructuración de los modelos, pues el entrenamiento durante el análisis 2 se realizó con la base sintética, la cual se caracteriza por tener 200 veces más datos de entrenamiento. Por este motivo, quizás un ajuste en la arquitectura de las redes, es decir, aumentar el número de capas ocultas o la cantidad de neuronas por capa puede inducir a tener una estimación más precisa



**Figura 58. Muestra comparativa de la métrica RMSE obtenida para predicciones (Fuente: Elaboración Propia)**

En cuanto a la comparación de rendimientos entre algoritmos, esta se realizará en función de las tablas siguientes:

**Tabla 53. Muestra los resultados promedio de la métrica RMSE junto con información estadística obtenida del proceso de validación 1 (Fuente Elaboración Propia)**

Información Métricas	RMSE	GBR	SVR	ANN	RNN
Max RMSE	0.171	0.114	0.136	0.6601	0.1936
Min RMSE	0.038	0.025	0.083	0.0442	0.0572
Promedio	<b>0.100</b>	<b>0.071</b>	<b>0.11</b>	<b>0.21</b>	<b>0.13</b>
Desviación Estándar	0.0470	0.0237	0.0203	0.1834	0.0457
Intervalo de Confianza 95%	[0.04 ; 0.17]	[0.029 ; 0.011]	[0.083 ; 0.135]	[0.054 ; 0.59]	[0.063 ; 0.191]

**Tabla 54. Muestra los resultados promedio de la métrica RMSE junto con información estadística obtenida del proceso de validación 2 (Fuente Elaboración Propia)**

Información Métricas	RMSE	GBR	SVR	ANN	RNN
Max RMSE	0.004	0.003	0.1	0.1570	0.1155
Min RMSE	0.002	0.002	0.083	0.0330	0.0283
Promedio	<b>0.003</b>	<b>0.003</b>	<b>0.09</b>	<b>0.08</b>	<b>0.05</b>
Desviación Estándar	0.0007	0.0005	0.0059	0.0416	0.0262
Intervalo de Confianza 95%	[0.002 ; 0.004]	[0.002 ; 0.003]	[0.083 ; 0.01]	[0.006 ; 0.64]	[0.024 ; 0.068]


Al analizar los valores de las tablas, se da cuenta inmediatamente que el algoritmo con mejor rendimiento es el GBR, pues, independiente del análisis, es el que posee menor promedio de RMSE y la menor desviación estándar de la métrica. Lo persigue en forma cercana el algoritmo RFR y, luego, con un error que crece aproximadamente 10 veces, el resto de los algoritmos.

Pese a lo último mencionado, es destacable que los valores de la métrica RMSE nunca superan la unidad, en ninguno de los dos análisis.


### 7.2.2 Métrica de desempeño MAE.

En el caso de la métrica MAE (Error Medio Absoluto), como su nombre indica, estima el error de precisión de las predicciones contrastando la media del valor absoluto de la diferencia entre el valor que predice el modelo y el valor de contraste. Al igual que en el caso del RMSE, la consigna es minimizar su valor, pues mientras más próxima a cero, mejor capacidad predictiva tendrá el modelo confeccionado.

A continuación, se exponen las figuras y tablas comparativas:



**Figura 59. Muestra comparativa de la métrica MAE obtenida para entrenamiento (Fuente: Elaboración Propia).**



**Figura 60. Muestra comparativa de la métrica MAE obtenida para predicciones (Fuente: Elaboración Propia)**

**Tabla 55. Muestra los resultados promedio de la métrica MAE junto con información estadística obtenida del proceso de validación 1 (Fuente Elaboración Propia)**

<b>Información Métricas</b>	<b>RMSE</b>	<b>GBR</b>	<b>SVR</b>	<b>ANN</b>	<b>RNN</b>
<b>Max MAE</b>	0.153	0.097	0.124	0.7862	0.1791
<b>Min MAE</b>	0.029	0.02	0.067	0.0220	0.0543
<b>Promedio</b>	<b>0.080</b>	<b>0.052</b>	<b>0.09</b>	<b>0.26</b>	<b>0.12</b>
<b>Desviación Estándar</b>	0.0409	0.0205	0.0194	0.2697	0.0438
<b>Intervalo de Confianza 95%</b>	[0.03 ; 0.146]	[0.023 ; 0.09]	[0.067 ; 0.123]	[0.03 ; 0.76]	[0.056 ; 0.176]

**Tabla 56. Muestra los resultados promedio de la métrica MAE junto con información estadística obtenida del proceso de validación 2 (Fuente Elaboración Propia)**

<b>Información Métricas</b>	<b>RMSE</b>	<b>GBR</b>	<b>SVR</b>	<b>ANN</b>	<b>RNN</b>
<b>Max MAE</b>	0.004	0.003	0.1	0.1570	0.1155
<b>Min MAE</b>	0.002	0.002	0.083	0.0330	0.0283
<b>Promedio</b>	<b>0.003</b>	<b>0.003</b>	<b>0.09</b>	<b>0.08</b>	<b>0.05</b>
<b>Desviación Estándar</b>	0.0007	0.0005	0.0059	0.0416	0.0262
<b>Intervalo de Confianza 95%</b>	[0.002 ; 0.0038]	[0.002 ; 0.003]	[0.083 ; 0.099]	[0.006 ; 0.64]	[0.024 ; 0.068]

Las conclusiones obtenidas para esta métrica son básicamente las mismas que se comentaron para el estudio del RMSE. Es decir, se repite la tónica de que el algoritmo GBR sea el que posee el mejor rendimiento promedio y con la menor desviación estándar.


Al igual que en el caso del RMSE, a posterior le siguen los algoritmos RFR y RNN, seguido por último por los algoritmos ANN y SVR.

En cuanto a los resultados del proceso con validación cruzada, vemos que la realizada en el análisis 2 posee mejores resultados. Lo cual resulta lógico, pues la base de datos de entrenamiento es 200 veces más grande, por lo que los algoritmos poseen más información para predecir un determinado valor.


Por último, se ha de mencionar que las métricas de desempeño son un buen primer parámetro comparativo, sin embargo, se deben poner a prueba los algoritmos configurados con información que no haya pasado por el proceso de entrenamiento. Solo así se tiene el antecedente para visualizar si el algoritmo está realizando un buen trabajo a la hora de estimar la vari.

### 7.3 Comparativa gráfica de predicciones a corto plazo.


A continuación. Se presentarán figuras comparativas para evaluar las predicciones obtenidas.




**Figura 61. Muestra gráfica comparativa entre predicciones a corto plazo del algoritmo RFR para análisis 1 y 2 (Fuente: Elaboración Propia)**




**Figura 62. Muestra gráfica comparativa entre predicciones a corto plazo del algoritmo GBR para análisis 1 y 2 (Fuente: Elaboración Propia)**



**Figura 63. Muestra gráfica comparativa entre predicciones a corto plazo del algoritmo SVR para análisis 1 y 2 (Fuente: Elaboración Propia)**



**Figura 64. Muestra gráfica comparativa entre predicciones a corto plazo del algoritmo ANN para análisis 1 y 2 (Fuente: Elaboración Propia)**



**Figura 65. Muestra gráfica comparativa entre predicciones a corto plazo del algoritmo RNN para análisis 1 y 2 (Fuente: Elaboración Propia)**

De las figuras recién expuestas, el análisis es bastante claro, pues los resultados obtenidos del análisis 2 son más precisos y con menor dispersión que lo estimado para el análisis 1 y esto independiente del algoritmo.

Es así como se da cuenta también que los coeficientes de determinación “ $R^2$ ”, son mayores y con mejor tendencia a la unidad que lo obtenido para el análisis 1, que incorporó la base de datos de entrenamiento real, pero a su vez la menos cuantiosa en cantidad de datos (45 vectores de atributos versus 800 que tenía la base de entrenamiento sintética obtenida para el análisis 2). Esto se aprecia con los valores expuestos en la tabla siguiente:

**Tabla 57. Muestra valores de los coeficientes de determinación obtenidos para los análisis 1 y 2 (Fuente: Elaboración Propia)**

Algoritmo	RFR	GBR	SVR	ANN	RNN
$R^2$ Análisis 1	0.424	0.762	0.776	0.668	0.834
$R^2$ Análisis 2	0.985	0.985	0.970	0.979	0.973

En cuanto a un análisis cualitativo de las gráficas presentadas, en lo referente al algoritmo RFR, si se observa la figura 61, se da cuenta que el análisis 1 posee una notoria dispersión y alto grado de error a la hora de predecir el valor de ICPU, es más, se aprecia una confusión importante del algoritmo a la hora de estimar valores bajos de ICPU. En cambio, para el análisis 2, se aprecia una notoria mejora.

Esto no tiene otra explicación que la cantidad de datos que poseía el conjunto de entrenamiento para rangos medios y bajos, en donde la información disponible era poca en relación en la disponible para rangos superiores de ICPU.

Para el resto de los algoritmos, el análisis es similar, pues todos presentan mejoras en su rendimiento a la hora de predecir la variable dependiente cuando reciben un entrenamiento con una cantidad abultada de datos. Ahora, sobre comentarios puntuales, existe una tendencia de los algoritmos SVR y ANN a sobreestimar el valor de ICPU, pues, como se observa de las figuras 63 y 64, los valores estimados por dichos algoritmos siempre se encuentran por sobre el ajuste lineal que se plantea en las gráficas.


Otro aspecto para destacar es que en el análisis 1, que posee el entrenamiento con la pequeña base de datos reales, se aprecia que el algoritmo que presenta los mejores resultados de predicciones es el RNN, lo que valida la idea anteriormente planteada de que un valor bajo de RMSE o MAE no necesariamente garantiza una mejor predicción, puesto que el algoritmo RNN posee métricas con peor desempeño que el algoritmo GBR, por ejemplo (0.134 versus 0.071).

Queda como evidencia entonces que, para un entrenamiento con pocos datos, el algoritmo de inspiración biológica RNN (Redes Neuronales Recurrentes) es el que presenta mejores resultados a la hora de compararse con los otros algoritmos.


Por último, en lo que concierne al análisis 2, los algoritmos con mejor desempeño son el GBR, RFR y RNN, estableciéndose entonces como principales candidatos a ser utilizados en la construcción de modelos de desempeño de pavimentos.

#### 7.4 Comparativa gráfica de predicciones a largo plazo.

Para realizar esta comparativa, primero que todo, se vuelven a exponer las predicciones a largo plazo obtenidas para los análisis 1 y 2 y, en contraste con las curvas teóricas de terreno planteadas en el capítulo 5.3.6 de este documento.



**Figura 66. Muestra modelos de desempeño obtenidos para el análisis 1 contrastados con las curvas de desempeño teóricas planteadas en 5.3.6 (Fuente: Elaboración Propia).**



**Figura 67. Muestra modelos de desempeño obtenidos para el análisis 2 contrastados con las curvas de desempeño teóricas planteadas en 5.3.6 (Fuente: Elaboración Propia).**

En cuanto a las predicciones a largo plazo, y correspondiente consecución de los modelos de desempeño, es necesario recordar que estas se obtienen a la hora de utilizar el algoritmo o predictor configurado en forma recursiva, es decir, que en base a su propio resultado de predicción en un instante  $t$ , lo utilice como input y pueda predecir el nuevo valor de la variable dependiente al ciclo siguiente  $t + 1$ .

Por lo demás, se recuerda que las predicciones se obtienen para una vía asfáltica del tipo troncal, con una solicitud de tránsito inicial de 5000 [veh/día], espesor de 160 [mm] y una condición inicial de ICPU de 10, es decir, un pavimento en su mejor condición y en el estado inicial de su puesta en servicio.

Teniendo claro y en mente lo anterior, lo primero que se realizará será analizar cualitativamente las figuras expuestas. En ese sentido, en lo que concierne a los resultados del análisis 1 expuesto en la figura 66, salvo por lo obtenido con el algoritmo RNN, el resultado para nada es bueno. El algoritmo ANN muestra un deterioro de la condición del pavimento simulado demasiado acelerada, el algoritmo SVR muestra un comportamiento demasiado distante a lo que exponen las curvas teóricas de terreno, los algoritmos RFR y GBR muestran un resultado más o menos coherente hasta el año 6, luego, el algoritmo GBR muestra un comportamiento asintótico que no desciende de un valor 6 de la condición del pavimento, en tanto que el algoritmo RFR muestra un deterioro acelerado hasta el año 10 comenzando a comportarse también asintóticamente sin descender de un valor de ICPU de 3.

En cuanto al análisis 2 expuesto en la figura 67, se aprecia un cambio en la forma de las curvas, puesto que estas resultan mucho más suaves sin dar saltos estrepitosos, característica obtenida solamente por poseer más datos de entrenamiento. Por lo demás, destaca que los algoritmos RFR, GBR y RNN muestran un comportamiento muy similar a las curvas teóricas de terreno, lo que remarca nuevamente la tesis de que los algoritmos de inteligencia artificial requieren de data abundante para que tengan un buen desempeño a la hora de estimar o predecir valores.

Con respecto a los algoritmos SVR y ANN, no es necesario realizar esfuerzos para notar que poseen un comportamiento distante de las curvas teóricas planteadas. Esto es una situación que se arrastra desde el análisis 1 y que ponen en tela de juicio su eficacia para obtener resultados predictivos de la condición de pavimentos a largo plazo.

Para realizar también, un análisis cuantitativo de los resultados obtenidos en la predicción a largo plazo, se decide estimar la métrica de desempeño RMSE para puntos determinados de las curvas teóricas de terreno que coinciden con una edad específica de naturaleza numérica entera, es decir, comparar las predicciones para años específicos, por ejemplo, el valor de ICPU que predicen los algoritmos en el año 4 versus el valor de la curva teórica de terreno para el mismo año.

El análisis se realiza solamente para los algoritmos RFR, GBR y RNN, puesto que son los que obtienen mejores resultados. Los algoritmos SVR y ANN se omiten del análisis.


**Tabla 58. Muestra métrica de desempeño RMSE obtenidas para los algoritmos RFR, GBR y RNN para análisis 1 (Fuente Elaboración Propia)**

Métrica RMSE / Algoritmo	RFR	GBR	RNN
Familia Macul	1.746	1.691	0.532
Familia Maipú	2.116	1.634	0.679
Promedio Familias	1.931	1.662	0.605
Desv. Estándar	1.278	1.427	0.453


**Tabla 59. Muestra métrica de desempeño RMSE obtenidas para los algoritmos RFR, GBR y RNN para análisis 2 (Fuente Elaboración Propia)**

Métrica RMSE / Algoritmo	RFR	GBR	RNN
Familia Macul	0.296	0.300	0.513
Familia Maipú	0.465	0.374	0.938
Promedio Familias	0.381	0.337	0.725
Desv. Estándar	0.394	0.356	0.687


Para tener una visualización más ilustrativa, se exponen las siguientes gráficas



**Figura 68. Muestra comparativa de métricas RMSE obtenidas por familia de pavimentos para el análisis 1 (Fuente: Elaboración Propia)**



**Figura 69. Muestra comparativa de métricas RMSE obtenidas por familia de pavimentos para el análisis 2 (Fuente: Elaboración Propia)**



**Figura 70. Muestra comparativa de métricas promedio RMSE obtenidas para análisis 1 y 2 (Fuente: Elaboración Propia)**

En cuanto a lo expuesto en las tablas 58, 59 y las figuras 68, 69 y 70, se aprecia inmediatamente que los resultados de la métrica RMSE obtenidos para el análisis 1 poseen un alto valor, siendo especialmente alto para el algoritmo RFR, le sigue el algoritmo GBR y, con el mejor resultado, el algoritmo RNN.

Esto no hace más que sostener la tesis de que, para obtener predicciones de precisión se requiere de una base de datos abultada para entrenar los algoritmos, puesto que no todos son capaces de interpretar comportamientos si es que poseen un nivel bajo de información, aspecto que se vislumbra claramente en las predicciones obtenidas de los algoritmos RFR y GBR.

En cuanto al análisis 2, se aprecia que la capacidad predictiva de los modelos es superior y las métricas de desempeño toman valores más bajos (a excepción del algoritmo RNN), ya sea en promedio o desviación estándar, esto queda claramente expuesto en los resultados que se muestran en las tablas 48 y 59.

Sobre rendimiento de los algoritmos, en lo que concierne al análisis 1, es decir el análisis con la pequeña base de datos reales, el algoritmo con mejor desempeño es el RNN, en tanto que para el análisis 2, es decir el entrenamiento con datos sintéticos y validado con los datos de terreno, el algoritmo con mejor performance resulta ser el GBR, seguido de cerca por RFR y, en último lugar, el algoritmo RNN


Por último, mencionar que, en todos los casos analizados, las métricas de desempeño son peores a medida que crece el horizonte de predicción, situación apreciable tanto en la figura 66 como la 67, en las que se da cuenta que los algoritmos siguen de cerca las curvas teóricas de terreno hasta el año 10, a posterior, la capacidad predictiva de los distintos algoritmos decae.

**7.5 Comparativa de modelos de desempeño con modelo “Markoviano”.**


Por último, los resultados de predicción a largo plazo son contrastados con el Modelo Markoviano confeccionado por Osorio, 2015. Este modelo es confeccionado con herramientas probabilísticas y predice la progresión del deterioro de pavimentos urbanos en el tiempo también con la métrica ICPU.

Por tal motivo, resulta de suma importancia la comparación, puesto que permite el contraste de enfoques distintos de modelación brindando luces de cual podría llegar a ser más preciso o que enfoque resulta de mayor conveniencia en virtud del escenario a modelar.

A continuación, se exponen los modelos de desempeño obtenidos con los algoritmos RFR, GBR, RNN contrastados con las curvas teóricas de terreno elaboradas y el modelo Markoviano confeccionado por Osorio, 2015.



**Figura 71. Muestra modelos de desempeño obtenidos contrastados con Modelo Markoviano y Curvas Teóricas de Terreno para Análisis 1 (Fuente: Elaboración Propia)**



**Figura 72. Muestra modelos de desempeño obtenidos contrastados con Modelo Markoviano y Curvas Teóricas de Terreno para Análisis 2 (Fuente: Elaboración Propia)**

Cualitativamente hablando, en lo que concierne al análisis 1, se aprecia claramente que el modelo que más se asemeja al comportamiento de las curvas teóricas de terreno es el Markoviano desarrollado por Osorio, 2015. De los algoritmos de Inteligencia Artificial entrenados, le persigue el algoritmo RNN y luego, sin tanta cercanía, los algoritmos RFR y GBR.

En el caso del análisis 2, vemos un comportamiento bastante similar entre los algoritmos configurados y el modelo Markoviano, es más, las distintas curvas toman un comportamiento notoriamente distinto recién en las proximidades del año 10. Cabe destacar que la predicción entregada por el algoritmo RNN va siempre por debajo de sus similares elaboradas con los algoritmos RFR y GBR, siendo entonces el modelo que presenta predicciones más conservadoras.

En cuanto a los algoritmos RFR y GBR, estos siguen un comportamiento casi calcado que solo se separa levemente hacia el año 14. Por lo demás, las curvas generadas por estos algoritmos siempre se muestran entre lo estimado por el algoritmo RNN y el modelo Markoviano, resultando, de alguna forma, como una estimación media a la hora de contrastar con el resto de los modelos.


Para realizar un análisis cuantitativo, se estima también la métrica RMSE que presenta el Modelo Markoviano a la hora de contrastarlo año a año con las curvas teóricas de terreno y, posteriormente, con el resultado obtenido para estas métricas para cada uno de los otros modelos.

**Tabla 60. Muestra métrica de desempeño RMSE obtenidas para los algoritmos RFR, GBR, RNN y Modelo Markoviano para análisis 1 (Fuente Elaboración Propia)**


Métrica RMSE / Algoritmo	RFR	GBR	RNN	Markoviano
Familia Macul	1.746	1.691	0.532	0.816
Familia Maipú	2.116	1.634	0.679	0.389
Promedio Familias	1.931	1.662	0.605	0.603
Desv. Estándar	1.278	1.427	0.453	0.592

**Tabla 61. Muestra métrica de desempeño RMSE obtenidas para los algoritmos RFR, GBR, RNN y Modelo Markoviano para análisis 2 (Fuente Elaboración Propia)**


Métrica RMSE / Algoritmo	RFR	GBR	RNN	Markoviano
Familia Macul	0.296	0.300	0.513	0.816
Familia Maipú	0.465	0.374	0.938	0.389
Promedio Familias	0.381	0.337	0.725	0.603
Desv. Estándar	0.394	0.356	0.687	0.592



**Figura 73. Muestra comparativa de métricas RMSE obtenidas por familia de pavimentos para el análisis 1 (Fuente: Elaboración Propia)**



**Figura 74. Muestra comparativa de métricas RMSE obtenidas por familia de pavimentos para el análisis 2 (Fuente: Elaboración Propia)**



**Figura 75. Muestra comparativa de métricas promedio RMSE obtenidas para análisis 1 y 2**  
**(Fuente: Elaboración Propia)**

Como primero, mencionar que los datos numéricos expuestos en las tablas 60 y 61 y en las figuras 73, 74 y 75, ratifican el comportamiento cualitativo descrito, es decir, para el análisis 1 los modelos que más se acercan al comportamiento esperado son el RNN y Markoviano. En tanto que, para el análisis 2, todos los algoritmos de Inteligencia Artificial, salvo el algoritmo RNN, mejoran su capacidad predictiva, siendo los que más se acercan al comportamiento de las curvas teóricas de terreno las predicciones realizadas por el algoritmo GBR, RFR y el modelo markoviano, quedando detrás el algoritmo RNN, pero, de todas formas, reflejando un modelo de desempeño coherente.

En cuanto a las predicciones para las distintas familias, se observa que la predicción para la familia de pavimentos de la comuna de Macul siempre resulta con mejores resultados de las métricas de desempeño cuando se comparan con las predicciones para la familia de pavimentos de Maipú, esto incluso incluye al modelo Markoviano con el cual se está contrastando.

Ahora, en cuanto a que modelo resulta “más preciso”, tomando en consideración el análisis 1, resulta con mejor performance el Modelo Markoviano, quien obtiene una métrica promedio de 0.603 en contraste con el modelo RNN que posee una métrica promedio de RMSE de 0.605. Pese a lo anterior, se destaca que ambos modelos obtienen un resultado que podría interpretarse como igual. Por lo demás, la desviación estándar del modelo RNN es menor que la del Markoviano notoriamente (0.453 vs 0.592),

Si interpretamos ahora lo obtenido para el análisis 2, se da cuenta que tanto los algoritmos RFR y GBR se ajustan de mejor forma a las curvas teóricas de terreno obteniendo un RMSE promedio de 0.394 y 0.356 respectivamente versus el promedio de 0.605 que posee el modelo Markoviano.

Los resultados obtenidos no hacen más que reafirmar la tesis de la importancia de los datos a la hora de modelar un proceso, puesto que el comportamiento en cuanto performance ya sea para el análisis 1 y 2, muestra que un conjunto de características bien nutrido, y que esté bien relacionado con la variable dependiente a predecir, permite que los modelos posean mejor capacidad predictiva.

Por último, se debe mencionar que, si bien hay un respaldo numérico de las sentencias expuestas, esto no deja de ser una estimación e inferencia, puesto que las curvas teóricas de terreno, tal como lo enuncia su título, son teóricas. Una serie de supuestos que permiten estimar su edad en base a la metodología de ventanas (Videla, et al., 1992) y que no deja de ser un comportamiento deducido u aproximado.

No existen mediciones constantes de la condición de un solo pavimento que permita generar una curva de desempeño en base a datos reales, por lo que es menester configurar un banco de datos en el país que almacene información en forma constante y que facilite la exploración de nuevas herramientas y enfoques de modelación.

## 7.6 Análisis Estadístico

De los resultados obtenidos para el Análisis 2, ya se expresó que los algoritmos RFR, GBR y RNN son los que presentan el resultado más cercano y similar a las curvas teóricas de terreno confeccionadas. Esto logra apreciarse en forma visual y puede dilucidarse también con los resultados obtenidos para las métricas de desempeño evaluadas. Sin embargo, en un último afán de refrendar lo anterior, se opta por estudiar las posibles diferencias existentes entre las predicciones entregadas por cada algoritmo y los datos reales de ICPU que se obtuvieron del proceso de auscultación en terreno, buscando analizar si existen o no diferencias significativas por medio de una prueba estadística.

Dicho lo anterior, se tuvo que buscar una prueba adecuada para estudiar los conjuntos de datos tanto de predicciones como de la data real de terreno, pues pruebas comunes como la prueba “T-Student” para la comparación de medias no resulta aplicable puesto que ninguno de los conjuntos de datos a comparar distribuye en forma normal.

Con la condicionante recién expuesta en evidencia, se optó por realizar pruebas estadísticas no paramétricas, puesto que son las aconsejables para realizar comparaciones entre conjuntos de datos que no distribuyen en forma normal (DATAtab, 2023).

La prueba estadística no paramétrica seleccionada fue la “Prueba U de Mann-Whitney”, la cual se utiliza para comprobar si existe una diferencia significativa entre dos muestras de datos y no es necesario que estos distribuyan normalmente (DATAtab, 2023). A fin de cuentas, es la contrapartida no paramétrica de la prueba “t” para muestras independientes.

Con respecto a la hipótesis que plantea la prueba, esta se expone a continuación:

$$\text{Pruba U de Mann – Whitney} = \begin{cases} H_0: \text{No hay diferencia entre los grupos} \\ H_1: \text{Existe diferencia entre los grupos} \end{cases} \quad (6)$$

En conocimiento de lo anterior, se realiza la prueba ayudándose de las pruebas preprogramados en lenguaje “R” en la librería “Stats” por medio del entorno de programación Rstudio®. Por lo demás, se utiliza un nivel de significancia estadística  $\alpha$  de 0.05, es decir, una probabilidad de 5% de concluir que existe una diferencia cuando en realidad no existe ninguna.

Realizada las pruebas comparativas, se obtienen los siguientes resultados

**Tabla 62. Muestra resultados de las Pruebas Estadísticas U Mann-Whitney realizadas a los conjuntos de datos reales y predicciones.**

Estadístico	Predicciones RFR vs Data Real	Predicciones GBR vs Data Real	Predicciones RNN vs Data Real
W	524	524	468
P - Value	0.5114	0.5116	0.1792

De estos resultados, se desprende que el valor P para cada una de las comparaciones realizadas es superior a la significancia de 0.05. Por tal motivo, la prueba permite interpretar que no existe evidencia estadística para rechazar la hipótesis nula, es decir, no existe evidencia para rechazar la hipótesis de que no existe diferencia entre los conjuntos de datos. En palabras simples, la prueba indica que no hay evidencia estadística para decir que las predicciones se alejan de los datos reales de terreno.

Por último, se señala que, con el resultado obtenido, ya no solo existe la evidencia visual y de las métricas de desempeño para indicar un buen resultado, sino que también existe la evidencia estadística para aseverar que los tres algoritmos en análisis poseen una buena performance y capacidad predictiva tanto para corto como largo plazo.

## **8 Conclusiones.**

### **8.1 Sobre los atributos explicativos.**

A modo de conclusión sobre este apartado, se menciona que logra modelarse el desempeño de los pavimentos urbanos para un escenario específico utilizando diversos algoritmos de inteligencia artificial.

Dicho proceso de modelación incorporó en su análisis la presencia de atributos explicativos ligados a la estructura del pavimento, como el espesor de carpeta asfáltica y el módulo resiliente de la subrasante, atributos ligados a la sollicitación de tránsito, como el caso de la consideración del TMDA y, también, ligados a la historia del pavimento, como lo es la inclusión de la condición previa del pavimento en el ciclo predecesor al de análisis.

De lo anterior, la variable de mayor importancia, deducida luego de realizar la prueba ANOVA e información Mutua, resulta ser el historial de condición previo al ciclo a predecir, luego el espesor de la carpeta asfáltica y, por último, con una importancia menor y nula, respectivamente, la sollicitación de tránsito y el módulo resiliente.

Sobre lo recién comentado, se destaca el hecho de que deben realizarse nuevos supuestos a la hora de estimar dichas variables si es que no se poseen datos fidedignos de terreno, pues los rangos de variación definidos o la característica establecida como atributo explicativa no fueron los idóneos. De esta forma, podría intentarse en futuros trabajos modelar el tránsito como peso de eje, ejes equivalentes o presencia o no de tránsito pesado. En tanto que, para la característica de la subrasante, quizás resulta razonable vincularla a la capacidad de soporte del suelo o CBR.

Por último, mencionar que el resultado, de alguna forma, podría ser beneficioso para un enfoque sencillo y rápido de modelación, puesto que si se busca implantar la metodología como herramienta en un municipio, estos no necesariamente cuentan con un presupuesto que permita realizar de manera continua la extracción de muestras testigos para monitorear la subrasante o realizar múltiples conteos de tránsito, por lo que si se demuestra que, dichos atributos explicativos pueden obviarse sin que el modelo pierda demasiada precisión, sin duda es una buena noticia para las agencias viales (municipios) de baja escala en el contexto de gestión de pavimentos urbanos.

### **8.2 Sobre la cantidad de datos de entrenamiento.**

Con respecto al entrenamiento de algoritmos de Inteligencia Artificial, ya se mencionó que en el mundo de la informática se posee el concepto de que mientras más datos mejor. Sin embargo, existen pocas referencias que indiquen una cantidad de datos de entrenamiento mínima.

El autor Chicco, 2017 menciona que la base de entrenamiento debe ser al menos 10 veces la cantidad de atributos explicativos. En ese sentido, en esta investigación se trabajó con 5 características explicativas de la variable dependiente y, para lo que fue el resultado del análisis 1, se dio cuenta de que el entrenamiento de los algoritmos se generó con 45 vectores que aunaban dichas características explicativas. Sobre el resultado, de poca calidad para la mayoría de los algoritmos a excepción del algoritmo RNN.

Contrastando con lo que fue el entrenamiento durante el análisis 2, a pesar de ser una base de datos completamente sintética, dicha base resultó ser 200 veces mejor que la utilizada en el análisis obteniendo muchos mejores resultados para la predicción ya sea a corto o largo plazo.

Con todo lo anterior expuesto, queda en evidencia que, para tener un nivel de precisión, al menos aceptable a la hora de utilizar Inteligencia Artificial, se requiere de una base de datos robusta y balanceada. Solo de esa forma los algoritmos son capaces de capturar los patrones deseados y calibrarse de forma correcta para realizar predicciones de la variable dependiente que se esté estimando.

En el caso puntual de Chile, no existe un banco de datos como si ocurre en América del Norte con la base LTPP (Long Term Pavement Performance) de la FHWA. Hace falta cultura de captura de datos y de socialización de estos.

Lo anterior es un tema que debe ponerse sobre la mesa, discutirse y poner manos a la obra para comenzar a cerrar la brecha que supone no contar con dicha cultura, pues poseer un banco de datos va en beneficio de la sociedad completa. En beneficio de aquel que quiere probar y plantear nuevos enfoques de modelación, en beneficio de las agencias viales que, a la larga, obtendrán más y mejores herramientas para complementar la toma de decisiones y de los usuarios de la red vial que podrán optar a un mejor nivel de servicio.

### **8.3 Sobre el rendimiento de los algoritmos utilizados.**

En cuanto al rendimiento de los algoritmos, si se centra el estudio en los resultados obtenidos en el análisis 1, el algoritmo con mejor rendimiento o performance es el RNN (Recurrent Neuronal Network). En tanto que, para el análisis 2, el que posee mejores resultados es el algoritmo GBR (Gradient Boosting Regressor), seguido de cerca por el algoritmo RFR (Random Forest Regressor) y, nuevamente el algoritmo RNN.

Sobre lo anterior, no sorprende el hecho de que tanto RFR y RNN tengan buenos rendimientos, pues son algoritmos que se han utilizado con éxito para predecir otras métricas de desempeño como PCI e IRI (Marcelino, et al., 2019; Choi y Do, 2019; Zhou, et al., 2021; Montecinos, 2022). Lo que, si resulta sorpresa, y grata por lo demás, es la buena performance que tuvo el algoritmo GBR, puesto que no había sido observado en otras investigaciones en las que se utilizaran algoritmos regresivos para modelar el desempeño de pavimentos, por lo que su buen rendimiento se transforma en un importante descubrimiento y, también, recomendación del algoritmo para utilizarse en tareas de predicción.

En cuanto a los algoritmos SVR y ANN, si bien tuvieron un rendimiento aceptable para predicciones a corto plazo, específicamente la predicción que permite obtener el valor de la variable dependiente para el ciclo inmediatamente sucesor, sus predicciones a largo plazo se muestran muy en disonancia con el comportamiento esperado para un modelo de desempeño de pavimentos, por lo que su uso no se recomienda para predicciones de esta índole.

### **8.4 Sobre la hipótesis de investigación.**

Primero que todo, se recuerda la hipótesis de investigación.

*“El rendimiento de la condición del pavimento urbano modelado con una combinación de algoritmos de Inteligencia Artificial para predicciones a corto y largo plazo presenta resultados más precisos que los modelos existentes para análisis a nivel de red.”*

Cabe recordar que lo existente es el modelo Markoviano planteado por Osorio, 2015 como herramienta de gestión del Sistema de Gestión de Pavimentos Urbanos de la Pontificia Universidad Católica de Chile (Solminihac, et al., 2018).

En cuanto a lo expuesto en la hipótesis, si consideramos los resultados del análisis 1, se da cuenta de que lo planteado no se consigue. Sin embargo, si se contrasta con los resultados del análisis 2, se da cuenta de que dos de los algoritmos de Inteligencia Artificial, GBR y RFR, poseen mejor desempeño tanto para las predicciones a corto como a largo plazo que el modelo Markoviano, resultado que validaría la hipótesis de investigación planteada.

Sin embargo, se debe ser cauto a la hora de obtener la conclusión final, puesto que en el análisis 2 los algoritmos se entrenaron con una base de datos completamente sintética, se destaca también que las curvas teóricas de terreno no son más que una estimación de cómo sería el comportamiento en el tiempo de un pavimento, es decir, no se cuenta con una curva de desempeño que esté compuesta exclusivamente con datos de terreno y con la que se pueda realizar una comparación certera de la precisión.

Con todo lo anterior, más que sentenciar, se presume que los algoritmos de Inteligencia Artificial otorgan predicciones más precisas que lo existente actualmente, pero decir que son, expresamente más precisas, resulta aventurado y con poca evidencia. Se recalca nuevamente que debe fomentarse la captura de datos en el tiempo y comparar los resultados, en algún minuto, con una curva real de terreno.

## 8.5 Sobre el enfoque de modelación.

Con respecto al enfoque de modelación, debe decirse que es un enfoque determinista, puesto que no se trabaja ni con distribuciones de probabilidad ni consideraciones de incertidumbre a la hora de obtener resultados.

Por lo demás, debe decirse que es un enfoque flexible que admite la integración de múltiples variables no solo numéricas, sino que también categóricas, por lo que permite incorporar aspectos que no podrían considerarse en un modelo de regresión simple ni probabilístico, como la adición de la clasificación funcional que se realiza en este estudio o, por ejemplo, de zonas climáticas. A fin de cuentas, tiene la ventaja de poder realizar un análisis de múltiples escenarios en un mismo modelo.

Se destaca también que el uso de este enfoque minimiza la intervención humana, pues, el proceso de buscar patrones que permitan inferir la variable dependiente se lleva a cabo en una caja negra no pudiendo intervenir, por ejemplo, en como los algoritmos RFR y GBR configuran las estructuras de cada uno de los árboles de decisión que conforman el algoritmo o como calibran los pesos de las neuronas los algoritmos de inspiración biológica.

Lo anterior es una ventaja del enfoque al momento de contrastar con el probabilístico utilizado en la elaboración de un modelo Markoviano, puesto que la construcción de las matrices de transición de probabilidad que se utilizan para obtener los vectores de estado y que, a la larga, permiten obtener la predicción, debe llevarse a cabo con una cantidad importante de datos de terreno que, si no logran obtenerse, deben estimarse con criterio de expertos.

El enfoque de modelación con inteligencia artificial ahorra ese paso al no necesitar la intervención de terceros para asociar patrones.

Se menciona también la ventaja referente al poco consumo de recursos que demandan los algoritmos, pues en menos de 15 minutos se puede tener entrenado y calibrado un algoritmo y utilizarlo satisfactoriamente para realizar predicciones.

Por último, mencionar que el enfoque tiene muchas bondades, sin embargo, si se carece de datos, dichas bondades no pueden aprovecharse y no se podrá tampoco esperar buenos resultados del proceso de modelación.

## 8.6 Sobre los objetivos trazados.

Primero que todo, recordemos los objetivos trazados para la investigación.

### General.

*Proponer y calibrar una metodología de modelación del comportamiento de pavimentos urbanos utilizando Machine Learning y Deep Learning, con aplicación a un conjunto de datos sintéticos, y validar con una base de datos reales de una red urbana acotada de la Región Metropolitana de Santiago de Chile.*

### Específicos.

- *OE1: Proponer y desarrollar metodología de modelación de la condición de pavimentos urbanos utilizando diferentes algoritmos de IA, específicamente Regresor de Bosques Aleatorios (RFR), Regresión de Vectores de Soporte (VSR), Regresor de Refuerzo de Gradiente (GBR), Redes Neuronales Artificiales (ANN) y Redes Neuronales Recurrentes (RNN). Indicando recomendaciones sobre el uso de variables y el tratamiento apropiado de la base de datos para su correcta aplicación.*
- *OE2: Aplicar la metodología de modelación utilizando una base de datos sintética que permita la simulación y entrenamiento de las distintas alternativas de algoritmos utilizados.*
- *OE3: Validar la metodología con la aplicación de los modelos a una base de datos real de una red urbana acotada de la Región Metropolitana de Santiago de Chile.*

Con respecto al Objetivo Específico 1, se afirma, con contundencia que se logró desarrollar una metodología que permite obtener modelos de desempeño de pavimentos urbanos utilizando algoritmos de Inteligencia Artificial, específicamente los algoritmos RFR, GBR, SVR, ANN y RNN. Además, se detallan en este documento indicaciones sobre el uso de variables, como seleccionarlas y como procesar no solo la base de datos, sino que también se detallan cada uno de los hiperparámetros que poseen los distintos algoritmos y que valores otorgarle a cada uno de ellos.

En cuanto al Objetivo Específico 2, se utiliza con éxito la metodología para calibrar los algoritmos utilizando no solo una base de datos sintética, sino que también con una pequeña base de datos reales de terreno que permite dilucidar la importancia de poseer una base de datos robusta y abultada para trabajar con algoritmos de Inteligencia Artificial,

Por lo demás, el entrenamiento y validación de los algoritmos se lleva a cabo tanto por el procedimiento de entrenamiento y validación simple como por el procedimiento de validación cruzada, realizando un estudio al detalle de la capacidad de generalización y predictiva de los diferentes algoritmos utilizados.

En lo que concierne al Objetivo Específico 3, se testea la performance de cada uno de los algoritmos configurados examinando su grado de precisión con los datos de terreno obtenidos de procesos de auscultación manual desde las comunas de Estación Central, Macul, Maipú y Ñuñoa para la predicción a corto plazo, en tanto que, para las predicciones a largo plazo, se conforman curvas teóricas de terreno con los datos de Macul y Maipú.

Sobre los resultados obtenidos, se valida la metodología al haber obtenido resultados de precisión tanto para la predicción a corto como largo plazo. Por lo demás, a la hora de contrastar con lo existente para el análisis del desempeño de pavimentos urbanos, dos de los modelos confeccionados mostrarían un grado de precisión mejor que el modelo Markoviano confeccionado por Osorio, 2015. Recordar que dicha conclusión es subjetiva al no contar con una curva real de terreno que permita hacer una sentencia definitiva.

Todo lo anterior conlleva al análisis del objetivo general, el cual se da por satisfecho puesto que, se propuso y calibró una metodología de modelación del desempeño de pavimentos. Dicha metodología se aplicó con éxito a diferentes algoritmos de Inteligencia Artificial configurando su entrenamiento con una base de datos sintética y se validaron sus resultados a la hora de generar predicciones a corto y largo plazo para una mini red de pavimentos que abarcaron las comunas de Estación Central, Macul, Maipú y Ñuñoa de la Región Metropolitana de Santiago de Chile.

Con lo anterior finalizan las conclusiones obtenidas del desarrollo de este trabajo, gracias, de antemano, por leer, interpretar, analizar y discutir cada una de ellas.

## **9 Recomendaciones e Investigación Futura.**

Como principales recomendaciones, se menciona lo siguiente.

1. Trabajar siempre con una base de entrenamiento que contenga al menos 20 veces la cantidad de atributos explicativos como cantidad de datos.
2. Incorporar de otra forma atributos característicos como el tránsito y la capacidad de soporte del suelo sobre el cual se establece el pavimento, pues en este estudio dichos atributos no mostraron especial relación con la variable dependiente.
3. Fomentar y promover campañas de auscultación y creación de un banco de datos nacional que permita probar y desarrollar nueva herramientas y enfoques de modelación.
4. Probar un nuevo set de hiperparámetros a la hora de modelar el desempeño de pavimentos con algoritmos de inspiración biológica (ANN y RNN), pues en este estudio no fueron los que obtuvieron mejores resultados.
5. Fomentar el Desarrollo de Herramientas de análisis como los Modelos de Desempeño para optimizar la toma de decisiones de las agencias viales y, a la larga, prestar un mejor nivel de servicio a los usuarios.

En cuanto a la investigación futura, se menciona lo siguiente.

1. Realizar un símil de esta metodología para pavimentos de hormigón.
2. Ampliar el escenario de modelación para incorporar en el análisis zonas y solicitudes climáticas.
3. Implementar las herramientas de Inteligencia Artificial a un software que sea comprensible, intuitivo y fácil de utilizar para las agencias de gestión de pavimentos

## 10 Referencias.

Andrade Valle, A. I. (2019). Mejora de la gestión del mantenimiento de pavimentos urbanos en la ciudad de Valencia a través de la predicción de su deterioro.

Bagnato, J. (2017). Qué es overfitting y underfitting y cómo solucionarlo. 04 de diciembre 2021, de Aprende Machine Learning Sitio web: <https://www.aprendemachinelarning.com/que-es-overfitting-y-underfitting-y-como-solucionarlo/>

Bianchini, A., & Bandini, P. (2010). Prediction of pavement performance through neuro-fuzzy reasoning. *Computer-Aided Civil and Infrastructure Engineering*, 25(1), 39-54.

Butt, A. A., Shahin, M. Y., Carpenter, S. H. & Carnahan, J. A., 1994. Application of Markov Process to Pavement Management Systems at Network Level. San Antonio, Texas, EUA, Transportation Research Board.

Chicco, D. (2017). Ten quick tips for machine learning in computational biology. *BioData mining*, 10(1), 1-17.

Choi, S., & Do, M. (2019). Development of the road pavement deterioration model based on the deep learning method. *Electronics*, 9(1), 3.


### Bibliografía

D.F.L. 1. Ley N° 18.695, Orgánica Constitucional de Municipalidades. Diario Oficial de la República de Chile, Santiago, Chile, 9 de mayo de 2006.

D.F.L. 1. Ley N° 19.175, Orgánica Constitucional Sobre Gobierno y Administración Regional. Diario Oficial de la República de Chile, Santiago, Chile, 8 de agosto de 2005.

Decreto 47. Diario Oficial de la República de Chile, Santiago, Chile, 5 de junio de 1992.

Fausset, L. (1994). What is a Neural Net?. *Fundamentals of neural networks: architectures, algorithms, and applications* D. Fowley, B. Baker, and A. Dworkin, eds., Prentice Hall, Englewood Cliffs, NJ, 3-4.

Gonzalez, L. (2022). Vectores de soporte regresión – teoría.  Aprende IA. <https://aprendeia.com/algorithmo-maquina-de-vectores-de-soporte-regresion-machine-learning/>

Gradient boosting algorithm for machine learning. (2023, 25 septiembre). AlmaBetter. <https://www.almabetter.com/bytes/tutorials/data-science/gradient-boosting>

Haddad, A. J., Chehab, G. R., & Saad, G. A. (2022). The use of deep neural networks for developing generic pavement rutting predictive models. *International Journal of Pavement Engineering*, 23(12), 4260-4276.

Hossain, M. I., Gopiseti, L. S. P., & Miah, M. S. (2019). International roughness index prediction of flexible pavements using neural networks. *Journal of transportation engineering, part B: pavements*, 145(1), 04018058.

Jorge González Ramírez. (19 de mayo 2021). Qué es y qué aplicaciones tiene una red neuronal artificial. 20 de noviembre de 2021, de Datacentric Sitio web: <https://www.datacentric.es/blog/insight/red-neuronal-artificial-aplicaciones/>

Kargah-Ostadi, N. y Stoffels, SM, 2015. Marco para el desarrollo y comparación exhaustiva de modelos empíricos de rendimiento de pavimentos. *Revista de ingeniería de transporte*, 141 (8), 04015012. doi:10.1061/(asce)te.1943-5436.0000779.

Lin, J. D., Yau, J. T., & Hsiao, L. H. (2003, January). Correlation analysis between international roughness index (IRI) and pavement distress by neural network. In *82nd Annual Meeting of the Transportation Research Board* (Vol. 12, No. 16, pp. 1-21).

Llopis, D. (2019). Metodología Experimental. 04 de diciembre 2021, de Universitat Politècnica de Valencia Sitio web:

<https://poliformat.upv.es/access/content/user/24389381/Contenido%20abierto%20al%20p%C3%BAblico/Metodolog%C3%ADa%20de%20la%20investigaci%C3%B3n/3.2%20Metodologi%C3%A1a%20experimental.pdf>

Marcelino, P., & Antunes, L. E., & Castilho Gomes, M. (2019). Machine learning approach for pavement performance prediction. *International Journal of Pavement Engineering*, 1-14.

Masui, T. (2022, 12 febrero). All you need to know about gradient boosting Algorithm – Part 1. Regression. Medium. <https://towardsdatascience.com/all-you-need-to-know-about-gradient-boosting-algorithm-part-1-regression-2520a34a502>

Mazari, M., & Rodriguez, D. D. (2016). Prediction of pavement roughness using a hybrid gene expression programming-neural network technique. *Journal of Traffic and Transportation Engineering (English Edition)*, 3(5), 448-455.

Ministerio de Obras Públicas. (2020). Chile 2020. Obras Públicas para el Desarrollo. Santiago: MOP. Chile.

Ministerio de Planificación y Cooperación. (1996). Metodología Proyectos de Mantenimiento Vial Urbano. Santiago: MIDEPLAN. Chile. Div. de Planificación, Estudios e Inversión.

Ministerio de Vivienda y Urbanismo. (2018). Manual Obras Viales, Pavimentación y Aguas Lluvias. Santiago: MINVU. Chile. Servicio de Vivienda y Urbanismo Metropolitano.

Montecinos, A. (2022). METODOLOGÍA Y APLICACION DE ALGORITMOS DE MACHINE LEARNING EN EL DESARROLLO DE MODELOS DE DESEMPEÑO DE PAVIMENTOS AEROPORTUARIOS EN CHILE.

Ñanculef, Ricardo. (2022). Arquitectura Básica de Redes Neuronales. Departamento de Informática UTFSM. Campus Santiago. Chile.

Osorio, A., Chamorro, A., Tighe, S., & Videla, C. (2014). Calibration and validation of condition indicator for managing urban pavement networks. *Transportation Research Record*, 2455(1), 28-36.

Osorio-Lird, A., Chamorro, A., Videla, C., Tighe, S., & Torres-Machi, C. (2018). Application of Markov chains and Monte Carlo simulations for developing pavement performance models for urban network management. *Structure and Infrastructure Engineering*, 14(9), 1169-1181.

Paytán Ordoñez, J. (2018). Estimación del Índice de Regularidad Internacional en Pavimentos Flexibles Usando Redes Neuronales Artificiales.

Prueba U de Mann-Whitney. (s/f). Datatab.es. Recuperado el 23 de octubre de 2023, de <https://datatab.es/tutorial/mann-whitney-u-test>

Ramírez, F. (2021). ¿Qué es y cómo funciona la Inteligencia Artificial? 10 de octubre del 2021, de Universidad de Chile Sitio web: <https://www.uchile.cl/noticias/173079/que-es-y-como-funciona-la-inteligencia-artificial>

Salesforce. (2018). Deep Learning y Machine Learning: las diferencias. 10 de octubre 2021, de Global Blogs Sitio web: <https://www.salesforce.com/mx/blog/2018/7/Machine-Learning-y-Deep-Learning-aprende-las-diferencias.htm>

Scikit-learn: Machine Learning in Python, Pedregosa et al., *JMLR* 12, pp. 2825-2830, 2011.

Solminiach H., Echaveguren T., Chamorro A. (2018). Gestión de Infraestructura Vial. Santiago, Chile: Ediciones Universidad Católica de Chile.

Solorio Murillo, J. R., Márquez Mendoza, Z. D., Montoya Ortega, M., Cárdenas Rodríguez, S. L., & Hernández Domínguez, R. I. (2014). Aplicación de métodos markovianos en el modelado del deterioro de carreteras. *Publicación Técnica*, (396).

Venegas, J. (2022). Desarrollo de una metodología de utilización de cámaras de bajo costo para la evaluación de pavimentos urbanos.

Videla, C., Echeverría, G., Gaete, R., & Caroca, A. (1992). Estudio para la Evaluación de la Eficacia de la Conservación en Pavimentos Asfálticos. Vol. IV: Sistema de Gestión de Pavimentos GIMP.

Wang, Z., Guo, N., Wang, S., & Xu, Y. (2021). Prediction of highway asphalt pavement performance based on Markov chain and artificial neural network approach. *The Journal of Supercomputing*, 77, 1354-1376.

Watanatada, T., Harral, C. G., Paterson, W. D., Dhareshwar, A. M., Bhandari, A., & Tsunokawa, K. (1987). THE HIGHWAY DESIGN AND MAINTENANCE STANDARDS MODEL. VOLUME 1, DESCRIPTION OF THE HDM-III MODEL. VOLUME 2, USER'S MANUAL FOR THE HDM-III MODEL. World Bank Highway Design and Maintenance Standards Series.

Yang, X., Guan, J., Ding, L., You, Z., Lee, V. C., Hasan, M. R. M., & Cheng, X. (2021). Research and applications of artificial neural network in pavement engineering: a state-of-the-art review. *Journal of Traffic and Transportation Engineering (English Edition)*, 8(6), 1000-1021.

Yao, L., Dong, Q., Jiang, J., & Ni, F. (2019). Establishment of prediction models of asphalt pavement performance based on a novel data calibration method and neural network. *Transportation Research Record*, 2673(1), 66-82.

Zhou, Q., Okte, E., & Al-Qadi, I. L. (2021). Predicting Pavement Roughness Using Deep Learning Algorithms. *Transportation Research Record*, 2675(11), 1062-1072

## 11 Anexos.

### 11.1 Base de datos de la mini red de pavimentos urbanos confeccionada

**Figura 76. Muestra base de datos de la mini red de pavimentos confeccionada (Fuente:**

**Elaboración Propia)**

Sección	CF	Traf. Total	Traf. Total 2	Espesor [mm]	Mr	ICPU 2022	ICPU 2023
26	Troncal	2335	2428	155	65	9.9	9.78
25	Troncal	4521	4702	131	64	9.88	9.74
30	Troncal	4663	4850	159	86	9.82	9.55
29	Troncal	4390	4566	135	70	9.55	9.32
33	Colectora	1168	1215	90	57	9.06	8.94
36	Colectora	1885	1960	86	48	8.95	7.06
42	Troncal	5076	5279	131	105	8.35	7.63
35	Colectora	335	348	120	59	7.32	6.5
41	Troncal	2451	2549	134	91	8.35	7.73
27	Colectora	625	650	106	34	6.93	6.28
34	Colectora	1050	1092	85	34	7.3	6.43
28	Colectora	1827	1900	127	46	5.95	4.22
40	Colectora	1209	1257	94	55	5.85	5.57
37	Colectora	1508	1568	122	40	3.58	2.73
39	Colectora	1230	1279	114	54	2.37	1.7
38	Colectora	387	402	85	59	2.03	1
31	Troncal	4245	4415	158	112	1.15	1
32	Colectora	1160	1206	104	46	1	1
2	Colectora	1669	1736	115	59	9.91	9.69
5	Colectora	1437	1494	92	42	9.73	9.54

Sección	CF	Traf. Total	Traf. Total 2	Espesor [mm]	Mr	ICPU 2022	ICPU 2023
12	Colectora	1064	1107	80	60	9.52	9.37
13	Colectora	204	212	86	52	9.5	9.24
14	Colectora	1249	1299	124	52	9.38	8.47
6	Colectora	463	482	94	35	9.33	8.9
4	Troncal	7891	8207	157	112	8.75	7.27
7	Colectora	1227	1276	116	41	8.74	6.58
8	Colectora	830	863	130	36	8.72	7.75
1	Colectora	1487	1546	100	39	8.54	7.44
10	Colectora	850	884	100	52	8.37	7.39
3	Troncal	8876	9231	135	108	7.92	4.67
11	Colectora	1051	1093	73	43	7.77	7.49
15	Troncal	8532	8873	159	61	5.76	5.63
9	Colectora	1625	1690	129	60	4.29	2.8
16	Troncal	6707	6975	137	116	3.65	1.92
19	Troncal	2253	2343	143	118	9.72	9.48
22	Troncal	8457	8795	143	80	9.72	9.4
20	Troncal	4534	4715	134	96	9.69	9.42
21	Troncal	3400	3536	145	73	9.41	8.2
17	Troncal	5293	5505	151	85	8.48	5.3
24	Colectora	665	692	73	46	7.29	7
23	Colectora	1716	1785	126	33	6.85	6.5
18	Troncal	2470	2569	141	91	2.84	2
55	Colectora	1742	1812	85	33	9.82	9.72
44	Troncal	7542	7844	149	100	9.76	9.71
58	Troncal	3187	3314	152	91	9.68	9.57
59	Troncal	5165	5372	136	79	9.6	9.38
43	Troncal	6036	6277	160	71	9.15	8.68
56	Colectora	373	388	73	39	8.78	8.21
50	Troncal	7366	7661	141	98	8.22	7.55
51	Troncal	5762	5992	151	83	7.26	6.52
48	Expresa	12758	13268	179	135	6.91	6.17
49	Expresa	13619	14164	164	172	6.73	5.99
52	Troncal	8728	9077	145	85	6.05	5.32
45	Troncal	5955	6193	153	110	5.02	4.32
46	Troncal	4331	4504	141	94	3.58	2.74
53	Troncal	3781	3932	151	71	3.4	2.52